

UNIVERSIDADE FEDERAL DE SÃO PAULO  
DEPARTAMENTO DE CIÊNCIA E TECNOLOGIA DO MAR  
ENGENHARIA AMBIENTAL

ISABELLE SARDINHA LEONARDO CAMPOS

**PREVISÃO DE IRRADIÂNCIA SOLAR NA REGIÃO SUDESTE DO BRASIL  
EMPREGANDO O MODELO DE MESOESCALA WRF AJUSTADO POR REDES  
NEURAIS ARTIFICIAIS (RNAS)**

SANTOS

2018

ISABELLE SARDINHA LEONARDO CAMPOS

**PREVISÃO DE IRRADIÂNCIA SOLAR NA REGIÃO SUDESTE DO BRASIL  
EMPREGANDO O MODELO DE MESOESCALA WRF AJUSTADO POR REDES  
NEURAIS ARTIFICIAIS (RNAS)**

Trabalho apresentado à banca examinadora da Universidade Federal de São Paulo, como requisito para a obtenção do título de bacharel em Engenharia Ambiental, sob a orientação do professor Doutor Fernando Ramos Martins e sob coorientação do Francisco José Lopes Lima.

**Santos**

**2018**

*“Tu julgarás a ti mesmo. É o mais difícil. É bem mais difícil julgar a si mesmo que julgar os outros. Se consegues fazer um bom julgamento de ti, és um verdadeiro sábio. É preciso exigir de cada um o que cada um pode dar.”*

(Antoine de Saint-Exupéry)

*Dedico este trabalho aos meus pais, Cintia e Marcelo (in memoriam). Afinal,  
aquilo que amamos sempre será parte de nós.*

## AGRADECIMENTOS

Agradeço, primeiramente, à minha mãe, Cintia Sardinha Leonardo Campos, a quem devo toda a minha gratidão. Àquela que foi minha fortaleza e motivação desde o início da minha jornada. Agradeço ao meu pai, Marcelo Neves Campos (*in memorian*) que sempre esteve presente em forma de luz.

Agradeço aos meus irmãos, Bruna Sardinha Leonardo Campos e Marcel Sardinha Leonardo Campos por sempre estarem de braços abertos quando a saudade fala mais alto. À minha avó, Maria Lucia Martins Sardinha, por ser minha incentivadora e não medir esforços para cuidar bem de mim e da minha família.

Agradeço ao meu namorado, Bruno Santos da Cruz Porto, por ser meu refúgio e me ensinar a enfrentar as dificuldades com leveza. À Jéssica, Thaiane, Ana Claudia, Dayene, Paula, Kelly, Maitê e Gionnara por definirem para mim o companheirismo e amizade. À todos os meus colegas de trabalho, Sueli, Rafael, Eugenio, Mahara, Marina, Medina e Ernesto (*in memorian*) agradeço sinceramente pelo aprendizado, incentivo e companhia no decorrer dos últimos anos.

Agradeço ao meu orientador, Fernando Ramos Martins, por depositar em mim a sua confiança desde o meu primeiro ano na UNIFESP. Por toda a dedicação com nosso trabalho, apoio, disposição e conhecimento durante todos esses anos. Agradeço também ao Francisco, por ser uma peça essencial na construção deste trabalho e no enriquecer do meu aprendizado.

Agradeço à UNIFESP e todo o seu corpo docente, pelo aprendizado de qualidade e demais oportunidades. Ao INPE, por ter oferecido a bolsa de Iniciação Científica que me introduziu à temática das Energias Renováveis. À todos as demais pessoas, amigos e familiares pelo companheirismo diário, e pela contribuição para o meu crescimento acadêmico, profissional e pessoal.

## RESUMO

A irradiância solar é um recurso energético vital para a manutenção da vida no planeta e para atendimento de demandas relativas às atividades humanas, tais como agricultura, geração de eletricidade e produção de calor. A irradiância solar que incide sobre a superfície é de natureza variável, principalmente devido às nuvens e aos ciclos sazonais. Este trabalho tem como objetivo avaliar a capacidade de um modelo numérico mesoescala em simular a evolução dos processos atmosféricos na região Sudeste do Brasil de forma a possibilitar seu uso para previsão de irradiância solar quando acoplado com uma metodologia para refinamento estatístico para redução dos desvios sistemáticos inerentes ao modelo de mesoescala. Neste sentido, o estudo baseou-se no uso de Redes Neurais Artificiais (RNAs) alimentadas por variáveis meteorológicas fornecidas pelo o modelo de mesoescala WRF para horizontes de curto prazo: 24 horas, 48 horas e 72 horas. As variáveis de saída do modelo WRF foram empregadas como preditores em modelos de RNAs. Este trabalho utilizou dados de irradiância solar incidente na superfície observados durante o ano de 2013 em estações operadas pelo INMET. Diversos experimentos numéricos foram realizados para ajuste e definição do conjunto de preditores e configuração das redes neurais. Parâmetros estatísticos para avaliação de desvios foram adotados da metodologia de previsão para validação da metodologia empregada no estudo. Os resultados obtidos mostram que as RNAs são uma excelente alternativa para previsão de irradiância solar em toda a Região Sudeste, se destacando, sobretudo, para previsões de até 24h em dias de céu claro.

Palavras-chave: Irradiância solar. Modelo de Mesoescala WRF. Redes Neurais Artificiais. Região Sudeste.

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>7</b>
<b>2. FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>9</b>
2.1 RADIAÇÃO SOLAR .....	9
2.2 MODELOS NUMÉRICOS DE PREVISÃO DO TEMPO .....	11
2.3 REDES NEURAIS ARTIFICIAIS .....	13
2.4 FUNCIONAMENTO DAS RNAs .....	13
<b>3. OBJETIVO.....</b>	<b>16</b>
<b>4. MATERIAIS E MÉTODOS.....</b>	<b>16</b>
4.1 ÁREA DE ESTUDO .....	16
4.2 BASE DE DADOS: .....	17
4.3 METODOLOGIA: .....	18
4.3.1 <i>Base de Dados Observados em Superfície: Qualificação dos</i> <i>Dados</i> .....	19
4.3.2 <i>Base de dados do modelo numérico WRF: .....</i>	20
4.3.3 <i>Desenvolvimento da modelagem utilizando RNAs .....</i>	22
4.3.3.1 Seleção dos preditores .....	22
4.3.3.2 Treinamento das RNAs .....	24
4.3.4 <i>Avaliação de confiabilidade das Previsões dos Modelos.....</i>	24
<b>5. RESULTADOS .....</b>	<b>26</b>
5.1 SELEÇÃO DAS ESTAÇÕES METEOROLÓGICAS.....	26
5.2 AVALIAÇÃO DA ARQUITETURA DA RNA.....	29
5.3 ANÁLISE DA IRRADIÂNCIA SOLAR PREVISTA PELO WRF E AJUSTADA PELA RNA .....	33
5.3.1 <i>Região Homogênea 1 .....</i>	34
5.3.2 <i>Região Homogênea 2 .....</i>	37
5.3.3 <i>Região Homogênea 3.....</i>	41
5.3.4 <i>Região Homogênea 4.....</i>	44
5.3.5 <i>Região Homogênea 5.....</i>	47
5.4 AVALIAÇÃO DAS PREVISÕES HORÁRIAS NO HORIZONTE DE 24H PARA CADA REGIÃO HOMOGÊNEA. ....	51
5.5 ANÁLISE DAS PREVISÕES DE IRRADIÂNCIA SOLAR PARA HORIZONTES DE 48H E 72H .....	58
5.5.1 <i>Região Homogênea 01 – A547.....</i>	59
5.5.2 <i>Região Homogênea 02 – A551.....</i>	60
5.5.3 <i>Região Homogênea 03 – A519.....</i>	61
5.5.4 <i>Região Homogênea 04 – A707.....</i>	62
5.5.5 <i>Região Homogênea 05 – A530.....</i>	63
<b>6. CONCLUSÕES .....</b>	<b>68</b>

## 1. Introdução

O aumento da demanda e consumo de energia decorrente do progresso tecnológico e do avanço no desenvolvimento humano são apontados como os fatores mais importantes na aceleração das alterações climáticas e ambientais observadas e descritas pela comunidade científica. O aumento da demanda energética em conjunto com a possibilidade de redução da oferta de combustíveis convencionais e a crescente preocupação com preservação do meio ambiente está impulsionando a comunidade científica a pesquisar e desenvolver fontes alternativas e renováveis de energia que produzam baixo impacto ambiental.

A nova consciência mundial, quanto à utilização dos recursos naturais e energéticos, tem apontado para a inserção de fontes de energia alternativas, que apresentem sustentabilidade não apenas sob o ponto de vista ambiental, mas também socioeconômico. Entende-se por energias renováveis todas as formas de energia cuja taxa de utilização é inferior a sua taxa de renovação, podendo-se citar a energia solar, eólica, da biomassa, geotérmica e hidroelétrica.

Com o crescimento esperado da economia brasileira, haverá uma demanda proporcionalmente crescente de energia [1]. As energias renováveis solar e eólica representam importante opção, não só pelas vantagens inerentes à diversificação e complementaridade das fontes de energia, como também pelo fato de que há grande pressão internacional para estabilização das taxas de emissão de carbono para a atmosfera, levando a redução do uso de combustíveis fósseis [2].

A radiação solar é a fonte primária de energia disponível ao planeta para a manutenção da vida, governando inúmeros processos naturais, tais como evaporação, ciclos diurno e sazonal de temperatura e fotossíntese, além de ter implicações importantes em diversas áreas de atividades humanas, como o a agropecuária, a engenharia, a arquitetura, a hidrologia e diversos outros setores do conhecimento. Diante disso, mudanças na quantidade de energia solar disponível em superfície têm consequências ambientais e socioeconômicas profundas [3].



A energia solar vem ganhando importância nos últimos anos, acompanhando a crescente demanda energética mundial. Embora seja uma fonte de energia abundante, tem a desvantagem de ser de difícil conversão quando comparado com a energia hidroelétrica e possui oferta inconstante na medida em que está sujeita à variabilidade natural, associada principalmente às nuvens e aos ciclos diurno e sazonal. Portanto, para ser aproveitada, são demandados estudos que possibilitem conhecer melhor a disponibilidade regional, a variabilidade temporal e a previsibilidade da irradiância solar na superfície terrestre. Informações provenientes da previsão de radiação solar incidente são de vital importância na operação de sistemas híbridos de geração de eletricidade, permitindo um gerenciamento mais eficiente das fontes de energia e o emprego otimizado de energia solar-fotovoltaica em prol da economia de outros recursos [4].

O aproveitamento da energia da radiação solar incidente na superfície da Terra é uma alternativa para complementar a matriz energética brasileira atual que se baseia principalmente em sistemas hidroelétricos e térmicos baseados em combustíveis fósseis [5, 6]. Por ser um país localizado em sua maior parte na região intertropical, o Brasil possui grande potencial de energia solar ao longo de todo o país. Mas para que se possa otimizar os investimentos para implantação de estruturas coletoras de energia solar e sua exploração eficiente, faz-se necessário conhecer os locais com maior disponibilidade, os potenciais de utilização e as incertezas da variabilidade climática que influenciam este recurso de energia. Porém, informações confiáveis sobre essa variabilidade ainda são escassas no Brasil. Martins e Pereira (2011) [7], Martins et al. (2006) [8] e Leal e Tiba (2006) [9], ao investigarem a disponibilidade e a variabilidade da irradiância solar no Brasil, enfrentaram muitas limitações em função da baixa densidade de estações radiométricas no território brasileiro.

Uma das ferramentas utilizadas com bastante frequência para suprimir a baixa densidade de estações é o uso de metodologias numéricas baseadas em dados de satélites [10, 11, 12]. Os modelos numéricos de mesoescala também permitem a obtenção de estimativas de irradiância solar sobre regiões extensas e em locais isolados com baixa presença de estações em operação [13].

O conhecimento e previsão do potencial disponível de energia solar tem um papel de extrema importância para apoiar o setor energético no

planejamento de operação do sistema elétrico do País e na operação de plantas de geração solar como as fotovoltaicas (PV) e solares térmicas (CSP) [8]. Além disso, outros setores da economia poderão se beneficiar do desenvolvimento de metodologias de previsão de irradiância solar a médio e longo prazo. Dessa forma, o desenvolvimento de ferramentas e serviços de meteorologia pode contribuir significativamente tanto na orientação de políticas de incentivo e regulamentação como no do setor energético e em outros setores como os agronegócios, a arquitetura e a construção civil.

## 2. Fundamentação Teórica

### 2.1 Radiação Solar

O Sol pode ser considerado a principal fonte da energia para os processos naturais que ocorrem no planeta Terra, uma vez que a radiação solar alimenta os processos térmicos, químicos e dinâmicos que ocorrem na superfície terrestre [14, 15, 16, 17]. A radiação proveniente do Sol é denominada radiação de onda curta uma vez que apresenta comprimentos de onda menores que 4  $\mu\text{m}$  de comprimento [13].


A radiação solar, ao percorrer a atmosfera, sofre diversas interações com os constituintes atmosféricos, sendo parte absorvida e parte refletida pelos constituintes atmosféricos (vapor d'água,  $\text{CO}_2$ ,  $\text{O}_3$  e  $\text{O}_2$  e outros gases) ou pela superfície terrestre [18, 19]. A **Figura 1** apresenta os espectros da radiação solar que atingem o topo da atmosfera e a superfície da Terra, sendo possível verificar a atenuação sofrida nos diversos comprimentos de onda da radiação solar ao atravessar a atmosfera.

A irradiância de ondas curtas que incide na superfície terrestre pode ser classificada como descrito por Plana–Fattori e Ceballos (2005) [20]:

- **Irradiância direta:** *fluxo de energia solar que não sofre interação radiativa de espalhamento e/ou absorção ao longo do percurso pela atmosfera até incidir numa superfície horizontal;*
- **Irradiância difusa:** *fluxo de energia solar que sofreu interação de espalhamento por constituintes atmosféricos (nuvens, moléculas, materiais particulados, etc.) na atmosfera antes de incidir numa superfície horizontal.*

*Essa irradiância é responsável pela iluminação de áreas que não recebem luz direta do Sol;*

- **Irradiância global:** *consiste no fluxo total de energia solar incidente numa superfície horizontal sendo determinada pela somatória das irradiâncias direta e difusa.*



**Figura 1:** Espectro de emissão de um corpo negro a 6000 K, e espectros da irradiância solar que incide no topo da atmosfera e em superfície horizontal ao nível do mar. (Fonte: Modificado de Robinson (1966) [21]).

A radiação solar que alcança a superfície é influenciada por diversos fatores tais como elevação solar, nebulosidade e profundidade ótica da atmosfera [22]. Com céu limpo, a radiação direta corresponde entre 60 a 87% da radiação global e, na presença de nebulosidade, a fração da radiação direta diminui [23, 17] em fração que depende do tipo de nuvem presente na atmosfera. A nebulosidade é o principal fator de atenuação da radiação solar global que incide na superfície, sobretudo em locais de baixa latitude, desenvolvendo um papel importante no balanço de energia da Terra [24].

Diversos estudos têm sido realizados a fim de entender e quantificar a influência das condições de nebulosidade sobre a quantidade de radiação solar incidente na superfície terrestre. Liou (1976) [25] calculou e avaliou processos de absorção, reflexão e transmissão de radiação solar em uma atmosfera com nuvens, demonstrando a quantidade de radiação refletida e absorvida pelos diferentes tipos de nuvens. Uma atmosfera com presença de nuvens

nimbostratus e cumulonimbus, por exemplo, refletem de 80 a 90% e absorvem de 10 a 20% da radiação solar incidente sobre elas [25]. Souza (1997) [26], Aguiar (1997) [27], Segal e Davis (1992) [28], Paliatsos et al (2003) [29], Souza et al. (2005) [30] e Silva (2007) [31] demonstraram que uma camada de nuvem pode causar aumento ou diminuição da radiação solar na superfície em ordem de 50%.

Outros processos físicos que ocorrem na atmosfera influenciam diretamente na dispersão da energia solar. O processo de espalhamento ocorre em todos os comprimentos de onda do espectro eletromagnético da radiação solar, se caracterizando pela remoção de energia da onda incidente pelas partículas ou moléculas de gases, além da dispersão dessa energia para outras direções [32].

As partículas aerossóis também influenciam fortemente no balanço radiativo da atmosfera, de forma direta ou indireta, no clima, na visibilidade e na química da atmosfera, em escalas locais, regionais e globais. Na presença desses particulados, é esperada uma diminuição da radiação solar que chega na superfície [33, 34]. A influência direta dos aerossóis ocorre a partir do espalhamento ou da absorção da radiação solar pelas partículas. Já o efeito indireto, ocorre quando os aerossóis atuam como núcleos de condensação de nuvens, alterando as propriedades físicas e ópticas das nuvens, como albedo e tamanho das gotas [35, 36, 37].

Assim, para modelagem numérica da transmitância atmosférica da radiação solar, as propriedades óticas atmosféricas devem ser conhecidas, sendo estas dependentes da cobertura de nuvens, concentração de aerossóis e outros constituintes atmosféricos. A previsão de radiação solar incidente na superfície depende então do conhecimento antecipado das condições atmosféricas futuras, que, com certo grau de incerteza, pode ser suprido a partir das várias variáveis meteorológicas previstas pelos modelos numéricos de previsão de tempo [13].

## 2.2 Modelos numéricos de previsão do tempo

Modelos numéricos de previsão do tempo são utilizados para realizar a previsão do tempo para até 15 dias adiante, baseiam-se na simulação

numérica dos processos físicos na atmosfera utilizando as equações diferenciais que os descrevem [37]. Para utilizar um modelo numérico de previsão do tempo é necessário obter informações das condições atuais da atmosfera. Esta informação é obtida através de uma rede de estações meteorológicas. As variáveis-chave são velocidade e direção do vento, temperatura, umidade relativa e pressão atmosférica [38]. Os modelos numéricos de previsão de tempo possuem códigos de parametrização de radiação, uma vez que a energia solar alimenta a quase totalidade dos processos atmosféricos e atua como forçante em movimentos de ar de diferentes escalas.

O processo de previsão de radiação solar é complexo e envolve diversas incertezas mesmo se para apenas um dia de antecedência. Parte da incerteza se relaciona as condições meteorológicas que interferem em processos físicos não-lineares de transmissão de radiação, desde o topo da atmosfera até a superfície. Não obstante, essas incertezas também se relacionam a própria imprecisão na obtenção de previsões das condições de tempo futuras pelos modelos numéricos, além das propriedades ópticas do estado atmosférico futuro, uma vez que a evolução do tempo meteorológico apresenta em parte natureza aleatória e não-linear.

O modelo atmosférico WRF (*Weather Research and Forecasting*) é um modelo de previsão numérico de tempo, desenvolvido para pesquisa e fins operacionais. O modelo WRF foi desenvolvido para ser uma ferramenta referência para simulação atmosférica, flexível e eficiente em variadas plataformas de computação. Ele é de domínio público, sendo disponibilizado gratuitamente [39, 40]. Esse modelo possui um código-fonte simples, facilitando o seu entendimento e aplicação. Diversas instituições e agências governamentais contribuíram no desenvolvimento do WRF, entre elas, o *National Center for Atmospheric Research* (NCAR), *National Oceanic and Atmospheric Administration* (NOAA), *Forecast Systems Laboratory* (FSL), *Air Force Weather Agency* (AFWA), *Naval Research Laboratory*, *Oklahoma University* e *Federal Aviation Administration* (FAA). As opções de métodos para parametrização de processos físicos na atmosfera foram sendo incorporadas ao modelo WRF com a intenção de produzir um único sistema de modelagem

integrado. Assim, o maior problema enfrentado no seu uso consiste em escolher um grupo de parametrizações que seja adequado às condições características da região de estudo e também à capacidade computacional disponível. O processo radiativo é o mais importante da atmosfera, sendo responsável por todo balanço de energia que alimenta os demais processos atmosféricos. O esquema de parametrização de radiação solar reproduz os efeitos da radiação de ondas curta e longa na atmosfera e no solo.

## 2.3 Redes Neurais Artificiais

Estudos têm mostrado que a previsão de radiação solar incidente na superfície com uso de modelos de mesoescala é sistematicamente superestimada [41, 42]. Métodos de refinamento estatístico são utilizados para redução dos desvios de previsões fornecidas pelos modelos de mesoescala, dentre eles, as redes neurais artificiais têm se destacado na comunidade acadêmica.

As redes neurais artificiais (RNAs) são ferramentas computacionais que armazenam conhecimento empírico a partir de exemplos e lembram a estrutura de raciocínio do cérebro humano [43]. As RNAs possuem um amplo campo de aplicação devido ao fato de sua alta capacidade de generalização, auto-organização e processamento temporal que possibilita a resolução de diferentes problemas, com diversos graus de complexidades [44].

## 2.4 Funcionamento das RNAs


As RNAs são compostas por unidades de processamento simples, denominadas neurônios, as quais possuem a função de computar e elaborar relações matemáticas a partir de dados de entrada recebidos. Estas unidades são dispostas paralelamente e interligadas com os neurônios próximos por conexões denominadas sinapses. A relevância de cada conexão para o processo em estudo está relacionada ao valor dos pesos sinápticos. Esses pesos sinápticos ponderam as entradas recebidas por cada neurônio e são

responsáveis por armazenar o conhecimento representado pela Rede Neural Artificial.

Para a solução de um problema, a RNA deve antes passar por uma fase de aprendizagem (treinamento) para ajuste das sinapses até proporcionarem à rede a capacidade de simular esse problema. Após o treinamento, os pesos para cada neurônio são fixados e a rede pode ser empregada como um modelo, estimando, portanto, saídas a partir de um conjunto de dados previamente disponibilizados como entrada.

Observando-se as diferentes arquiteturas descritas na literatura por Hebb (1949) [45], Rosenblat (1958) [46], Widrow e Hoff (1960) [47], Minsky e Papert (1969) [48] e Rumelhart (1986) [49], verifica-se que as RNAs têm suas estruturas organizadas em camadas, podendo ser uma ou mais camadas. As RNAs com multicamadas possuem um conjunto de neurônios de entrada, uma camada de saída e uma ou mais camadas intermediárias, como pode ser visto na **Figura 2**. Em tal imagem, pode-se verificar três neurônios de entrada, duas camadas intermediárias com 4 neurônios cada e uma camada de saída com um neurônio, o que significa que há uma única informação como saída.

O modelo representado na **Figura 2** é um dos mais utilizados na atualidade em numerosas áreas da ciência e tecnologia devido ao seu potencial de uso para ajustes funcionais, uma vez que possui capacidades universais de aproximação [50, 51]. Apesar disso, não há um método que predetermine a combinação de camadas e neurônios de uma RNA, uma vez que isso depende dos processos físicos envolvidos no estudo e do conjunto de dados de treinamento que será utilizado como preditores (dados de entrada) para a simulação. Cabe ao pesquisador, portanto, construir diferentes modelos e escolher aquele que alcança um treinamento com maior confiabilidade (menores desvios em relação aos valores observados) e, portanto, melhor se ajusta a aplicação desejada.



**Figura 2:** Modelo de uma RNA multicamadas (Fonte: Guarnieri, R. A., 2006 [13])

As RNAs são ferramentas que podem resolver diversos problemas de cunho geral, tais como controle, processamento de imagem e sinais, modelagem, categorização e previsão, aplicáveis a muitas áreas do conhecimento [43]. Na última década, as RNAs têm sido crescentemente aplicadas na estimativa e previsão de disponibilidade de recursos energéticos renováveis [42]. Dentre esses, diversos estudos publicados descrevem aplicações de RNAs com o intuito de previsão ou determinação de radiação solar incidente na superfície.

Al-Alawi e Al-Hinai (1998) [52] empregaram a metodologia de redes neurais para estimar valores médios mensais de radiação solar global, utilizando valores diários de pressão, temperatura, umidade relativa, velocidade do vento, duração do brilho do Sol e latitude como dados de entrada. Esse estudo obteve previsões de irradiação solar global com erro médio absoluto (MAPE) de 5,43%. Mohandes e cols. (1998) [53] utilizaram a duração do brilho do Sol, latitude e longitude de 31 estações solarimétricas na Arábia Saudita, para o treinamento de redes neurais artificiais com o intuito de obter estimativas de irradiância solar na superfície. As estimativas obtidas apresentaram desvios MAPE de 4,49%. Kalogirou et al. (2002) [54] usaram o método de redes neurais recorrentes para estimar o máximo de irradiação solar na superfície utilizando valores de temperatura e umidade relativa do ar como dados de entrada. Os autores encontraram correlações entre valores estimados e observados variando entre 98,6% e 98,8%. Um estudo de refinamento estatístico das previsões do modelo de mesoescala Eta/CPTEC foi realizado visando obter previsões de radiação solar incidente na superfície com desvios menores do que aqueles apresentados pelas previsões do modelo [13].



O uso de redes neurais tipo perceptron multicamadas possibilitou uma redução significativa dos desvios das previsões realizadas pelo modelo de mesoescala.

Em resumo, o emprego de redes neurais artificiais é justificável pela sua conhecida capacidade de reconhecimento de padrões e ajuste funcional, e por proporcionar bons resultados em problemas que apresentem elevado grau de não linearidade, como é o caso da previsão numérica da irradiância solar incidente na superfície.

### **3. Objetivo**

Este trabalho tem como objetivo avaliar a capacidade de um modelo numérico regional de mesoescala, acoplado com um modelo de redes neurais, em representar os processos atmosféricos típicos da região Sudeste do Brasil, possibilitando o uso da metodologia para previsão de irradiação solar incidente na superfície para horizontes de curto prazo: 24h, 48h e 72h.

### **4. Materiais e Métodos**

#### **4.1 Área de Estudo**

A Região Sudeste do Brasil compreende uma área de 924.935 km<sup>2</sup>, que abrange os Estados de Minas Gerais, Espírito Santo, Rio de Janeiro e São Paulo, onde vivem em torno de 78,5 milhões habitantes, correspondendo a aproximadamente 42,6% do total do País (estimativa cf. Datasus – Ministério da Saúde). A elevada concentração populacional torna a Região Sudeste muito suscetível às condições de tempo e clima, visto que, elas condicionam o desenvolvimento de importantes atividades econômicas, como a agricultura, o abastecimento urbano e a geração de energia hidroelétrica [55].

Grande parte do território do Sudeste brasileiro localiza-se entre as latitudes 14° S a 25° S, estando sujeita a um fluxo de energia expressivo ao longo do ano, alta variabilidade pluviométrica no espaço e no tempo e elevada evaporação em latitudes mais baixas. Estes aspectos fazem com que a região apresente uma grande variação de regimes climáticos, entre o tropical e o subtropical [54].

No verão austral (DJF), a atividade convectiva pode ser derivada de fatores como a umidade do ar e a instabilidade vertical da atmosfera, que constituem as forçantes termodinâmicas (e.g convecção local), bem como a existência de mecanismos dinâmicos que constituem as forçantes dinâmicas [56]. A Zona de Convergência Intertropical (ZCAS), os Sistemas Frontais, e o padrão de trem de onda que conecta a região tropical e extratropical favorecem a formação e o desenvolvimento de nuvens no Sudeste brasileiro [57].

A menor atividade convectiva da Região ocorre no inverno austral (JJA), associada a atuação da Alta Subtropical do Atlântico Sul (ASAS) que nesta época do ano localiza-se mais a oeste de sua posição climatológica, se estendendo até o Sudeste do Brasil. Dessa forma, desfavorece a formação de nuvens sobre o Sudeste Brasileiro dado o movimento descendente do ar intrínseco deste sistema [57]. Neste período do ano, a nebulosidade ocorre quando os sistemas frontais e ciclones extratropicais conseguem se sobrepor a influência da ASAS [58].

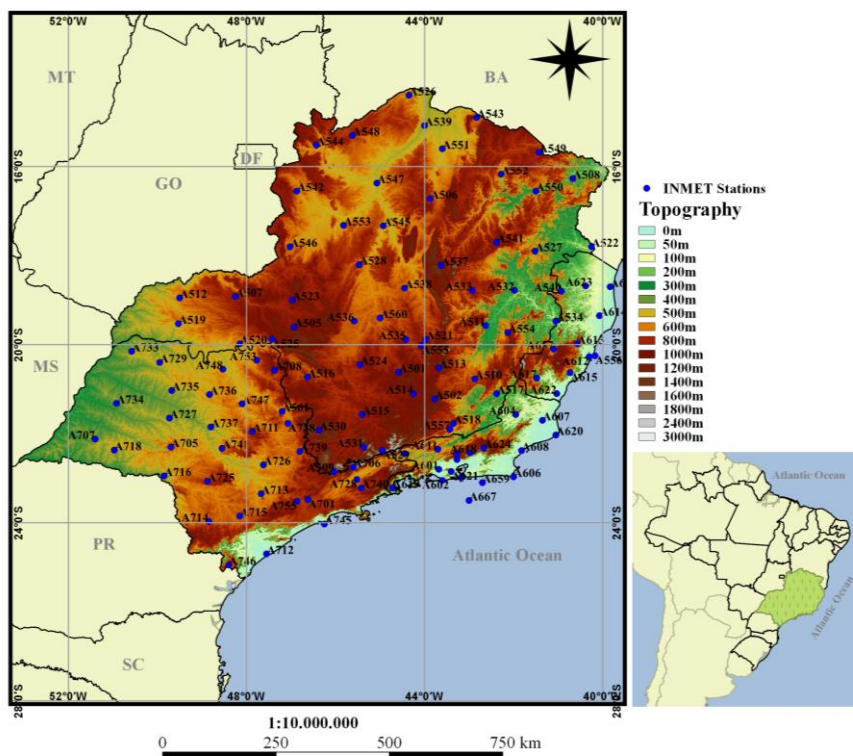
Sistemas meteorológicos que também atuam sobre o Sudeste são as Linhas de Instabilidade (LI), Complexos Convectivos de Mesoescala (CCMs), bloqueios atmosféricos, brisas [58] e a convecção orográfica, visto que a região apresenta um grande contraste entre áreas de planícies e planaltos, com gradientes que variam desde o nível do mar até altitudes superiores a 2000m.

#### 4.2 Base de Dados:

Para o desenvolvimento deste trabalho de conclusão de curso, as seguintes bases de dados foram utilizadas:

- ➔ Dados horários de irradiação solar global observados em 116 estações meteorológicas automáticas localizadas em na Região Sudeste do Brasil e operadas pelo Instituto Nacional de Meteorologia (INMET). O período de estudo compreende o ano de 2013. As estações contêm sensores para a medição de parâmetros meteorológicos como pressão atmosférica, temperatura, precipitação, radiação solar, entre outras. A Figura 3 mostra a localização das estações automáticas.

→ Dados de saídas de modelo WRF que serão utilizados para inicialização das simulações com os modelos de redes neurais.



**Figura 3:** Distribuição espacial das estações automáticas do INMET localizadas na região Sudeste do Brasil (Fonte: Lima, F. J. L, 2015 [4]).

#### 4.3 Metodologia:

Atualmente, os modelos atmosféricos de circulação geral - Atmospheric General Circulation Models (AGCM's) apresentam uma boa resolução espacial, o que contribui para a boa qualidade das previsões de tempo. Entretanto, para tomada de decisão ao nível regional/local, tanto pelo estado quanto pela sociedade civil, há uma demanda por uma maior resolução destas previsões e dos seus cenários, já que a variabilidade espacial e temporal da precipitação, associada com processos físicos não resolvidos em AGCMs pode afetar de forma significativa determinadas atividades econômicas.

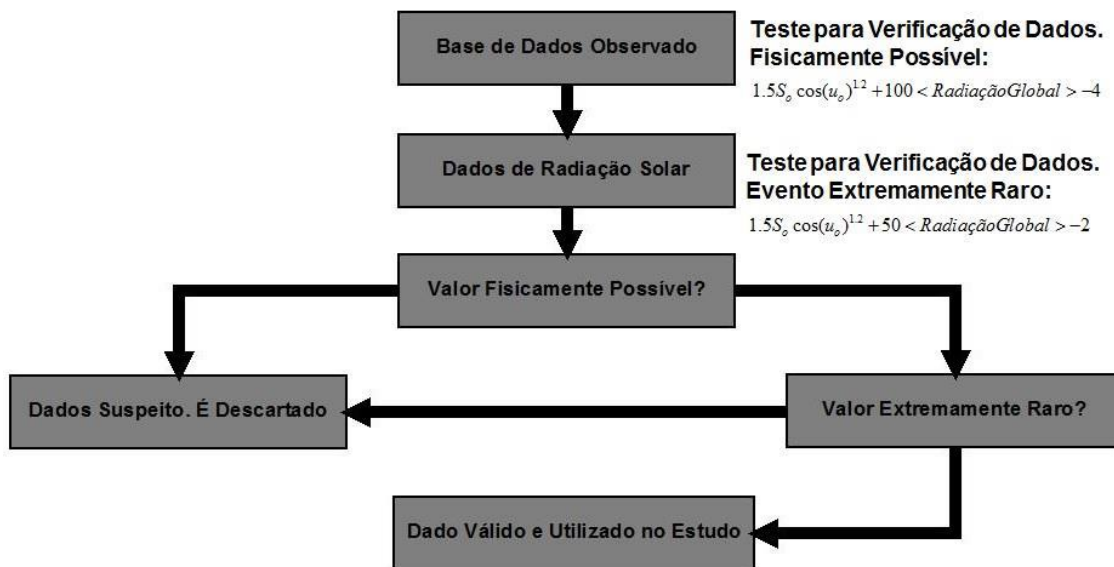
O setor de energias renováveis, especialmente a energia eólica e solar, cujo crescimento tem sido acentuado, também requer de informação de alta

resolução espacial para planejamento de suas ações, bem como para avaliação dos potenciais impactos da variabilidade climática de origem natural ou antrópica sobre a disponibilidade dos recursos energéticos renováveis na região. Com o propósito de se obter uma previsão de curto prazo com baixa incerteza para uma dada região de interesse, foi desenvolvida uma metodologia com base no uso de dados produzidos por um modelo numérico de mesoescala em conjunto com o emprego de um refinamento estatístico para que sejam diminuídos os erros sistemáticos dos modelos. A metodologia empregada foi subdividida em tarefas específicas, descritas nos itens a seguir.

#### 4.3.1 Base de Dados Observados em Superfície: Qualificação dos Dados

Alguns fatores podem afetar a confiabilidade dos dados medidos por equipamentos automáticos como os piranômetros, como a interrupção da alimentação do sensor, as descargas elétricas, as mudanças no ambiente onde está localizado o equipamento, entre outras. A qualificação dos dados observados em superfície consiste em analisar os arquivos estruturalmente realizando uma análise exploratória que consiste em manipulação, comparação com critérios de qualidade estabelecidos internacionalmente e exclusão ou não das séries de dados ou estações suspeitas de falhas no processo de aquisição. O controle de qualidade dos dados observados de irradiação solar se faz necessário para minimizar a possibilidade de uma análise tendenciosa, devido à baixa confiabilidade dos dados observados.

A adoção da qualificação permitiu a definição das estações foram utilizadas nesse estudo, tanto para a etapa da Análise de Agrupamento, nos testes de sensibilidade das parametrizações de radiação do WRF. Neste estudo, a qualificação dos dados empregada por Lima et. al, 2018, consistiu em um processo de qualificação similar ao adotado para estações participantes da BRSN (*Baseline Surface Radiation Network*), coordenado pela WMO (*World Meteorological Organization*) [7, 59]. A Figura 4 apresenta o fluxograma do algoritmo de qualificação empregado.



**Figura 4.** Fluxograma do procedimento para controle de qualidade dos dados de irradiação solar coletados pelo INMET (Fonte: Lima, F. J. L, 2015 [4]).

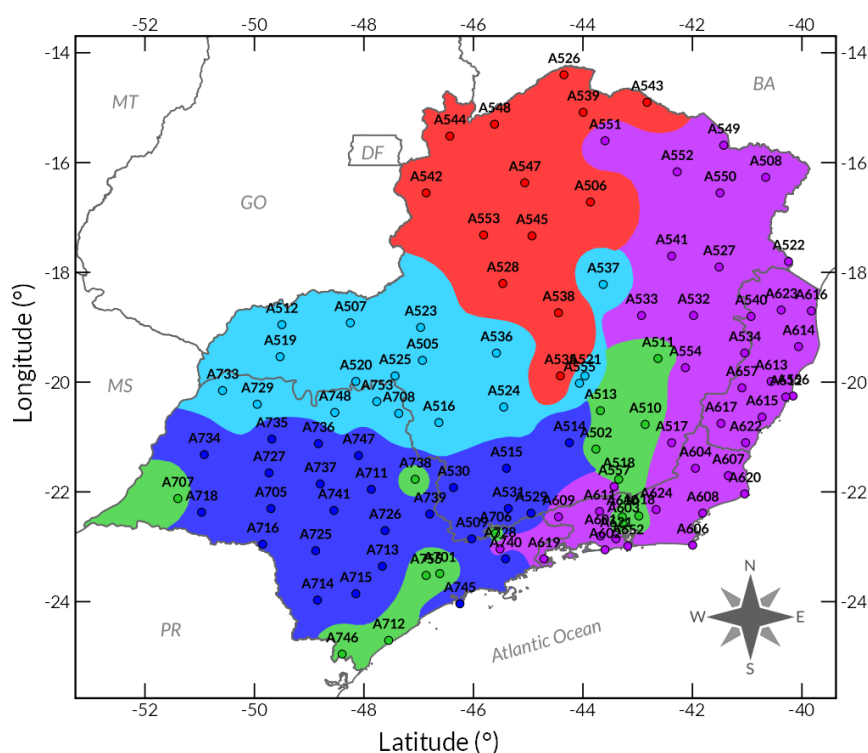
Para análise qualitativa, foi considerada a representatividade dos horários de medição da irradiação solar nas estações selecionadas, somente utilizando os dados onde cada dia possuisse ao menos nove medições para radiação solar. Além disso, também foram desconsideradas as estações que continham série de dados medidos com menos de 20 dias ao mês e 8 meses ao ano.

#### 4.3.2 Base de dados do modelo numérico WRF:

O método de análise de cluster, ou análise de agrupamento (AA), é um método eficaz para a identificação de regiões homogêneas. O objetivo principal do uso de análise de agrupamento nesse trabalho foi identificar áreas da Região Sudeste que apresentem características homogêneas sob o ponto de vista de irradiação solar na superfície e, com isso, configurar de forma mais regional o modelo de mesoescala WRF selecionando a melhor parametrização para toda a Região Sudeste

A análise de agrupamento para a região Sudeste, utilizada neste trabalho, foi elaborada por LIMA et al. (2018) [60] utilizando a média mensal da irradiação solar dos dados qualificados na etapa anterior em cada estação

meteorológica. O método hierárquico aglomerativo de Ward [61] foi adotado com a distância Euclidiana como função de agrupamento. Os autores identificaram cinco regiões homogêneas em termos de irradiação solar cujas localizações estão apresentadas na Figura 5. Os números em cada região no mapa representam a identificação das estações meteorológicas. Como a proximidade física das localidades não garante similaridade de características de irradiação solar, pode-se observar a ocorrência de áreas com características similares separadas geograficamente.



**Figura 5.** Localização das regiões homogêneas tomando em consideração a irradiação solar na superfície e temperatura do ar. Região 1 (Vermelho) Região 2 (Roxo) Região 3 (Azul Claro) Região 4 (Verde) e Região 5 (Azul Escuro). (Fonte: Lima, F. J. L, 2018 [60]).

As principais parametrizações físicas do modelo numérico de mesoescala WRF estão divididas em cinco categorias distintas: microfísica, parametrização de nuvens, parametrização da CLP, modelos de ocupação do solo e radiação. As parametrizações utilizadas para o Sudeste foram definidas por Lima et al. (2018) [60] e estão listadas na **Tabela 1**. O modelo WRF foi executado para toda a região utilizando o supercomputador TUPÃ instalado no

INPE em Cachoeira Paulista. A extração e concatenação dos dados foram realizadas por Lima (2018) [60] de modo a formarem séries temporais para cada uma das estações utilizadas no estudo. Em seguida, foi realizada a sincronização no tempo entre os dados modelados e os dados medidos. O conjunto de dados sincronizados foi utilizado para configurar e executar as redes neurais utilizadas para a previsão de irradiância solar incidente na superfície.

**Tabela 1.:** Parametrizações utilizadas no modelo numérico de mesoescala WRF.

Parametrizações	
<b>Camada limite superficial</b>	Eta similarity
<b>Camada limite atmosférica</b>	MYJ PBL
<b>Superfície do Solo</b>	Noah Land Surface Model
<b>Microfísica</b>	WSM6
<b>Radiação de onda longa</b>	RRTMG
<b>Radiação de onda curta</b>	RRTMG
<b>Cúmulos</b>	Grell 3D

#### 4.3.3 Desenvolvimento da modelagem utilizando RNAs

##### 4.3.3.1 Seleção dos preditores

A seleção de preditores é uma etapa que exige conhecimento sobre os processos físicos presentes na interação da radiação solar incidente na atmosfera. A utilização de muitos preditores pode agregar uma complexidade desnecessária à rede, sendo assim, é necessária uma seleção precisa, a fim de reduzir o número de preditores utilizados sem aumentar a incerteza das saídas produzidas pela RNA. Para otimizar o teste das possíveis combinações de preditores, deve-se utilizar o embasamento físico ou estatístico. Neste trabalho, a seleção de preditores foi realizada com base em alguns trabalhos realizados anteriormente por outros pesquisadores. Utilizou-se, oito preditores definidos como os melhores para a previsão de irradiação solar incidente descritos em Guarnieri (2006) [13], mas substituindo a radiação no topo da

atmosfera (TOA) pela irradiância de céu claro (*clearsky*). Os demais preditores são a *temperatura*, *umidade relativa*, *cobertura de nuvens altas*, *nuvens médias* e *nuvens baixas*, *água precipitável* e *velocidade do vento zonal*. Por fim, houve a inclusão do dia juliano e *hora*, com a finalidade de buscar um padrão temporal as redes [4].

A partir dos dados de umidade relativa ( $r_{h2}$ ) e de temperatura ( $t_2$ ) fornecidos pelo modelo WRF para a altura de 2 metros acima da superfície, foi calculado o conteúdo de água precipitável ( $pw$ ). O cálculo foi realizado de acordo com a relação empírica formulada por Leckner (1978) [62] e descrita abaixo na 03:

$$pw = \frac{0,493r_{h2}p_s}{t_2} \quad (03)$$

$$p_s = e^{\left(\frac{26,23-5416}{t_2}\right)} \quad (04)$$


onde  $p_s$  é a pressão de saturação de vapor d'água e  $t_2$  é a temperatura do ar em Kelvin. A Equação 03 determina a água precipitável nas condições normais de temperatura e pressão. Apesar de alguns estudos indicarem que valores de água precipitável obtidos através do uso de formulações empíricas são imprecisos [63, 64] a formulação de Leckner é mencionada como uma das que apresenta melhores resultados [65]. Esta variável foi calculada para cada passo de tempo, de todos os dias que compõem o conjunto de dados do WRF.

As RNAs do tipo MLP foram empregadas no estudo devido à sua capacidade de aproximação de qualquer função contínua aliada à capacidade de generalização. A função de transferência do tipo tangente hiperbólica foi utilizada para os neurônios nas camadas intermediárias e de saída. A literatura menciona que a utilização da função sigmoidais nas camadas escondidas é o que proporciona a capacidade de simular fenômenos não lineares pela RNA [66].

Com o número de preditores para a RNA definidos, o próximo passo foi determinar o número adequado de neurônios nas camadas ocultas. Quanto maior este número, maior a flexibilidade da rede para simular os processos



físicos na atmosfera; no entanto, maior também é a dificuldade de treinamento e maior o risco de sobre ajuste da rede. Guarnieri (2006) [13] e Lima [4] verificaram que as RNAs com duas camadas escondidas levaram a resultados ligeiramente melhores do que aqueles com o emprego de apenas uma camada escondida. Segundo os autores, a topologia ( $RNA-(n)-(2n)-(n)-alvo$ ) produziu melhores resultados (onde  $n$  é o número de preditores). A Figura 5 apresenta a configuração da RNA escolhida, para melhor visualização.



**Figura 6.** Modelo da RNA com duas camadas ocultas, com configuração RNA-(n)-(2n)-(n)-alvo (Fonte: Matlab).

#### 4.3.3.2 Treinamento das RNAs

Durante o treinamento foi utilizado o método proposto por Reed (1993) [67], onde os dados foram divididos em conjuntos na proporção de 60% dos dados para treinamento, 30% dos dados para a validação e 10% dos dados para o teste. É importante mencionar que, para o ajuste de qualquer modelo estatístico, é comum realizar o ajuste e o teste do modelo com conjuntos de dados independentes.

Foram efetuados 100 treinamentos pelo algoritmo de retropropagação de Levenberg-Marquardt para localização de cada estação, e, calculados os erros quadráticos médios ( $RMSE$ ), erros médios ( $ME$ ) e coeficientes de correlação  $R$  entre as saídas das RNAs e seu respectivo alvo no conjunto de teste.

#### 4.3.4 Avaliação de confiabilidade das Previsões dos Modelos

Para a avaliação das previsões de irradiância solar dadas pela RNA e pelo modelo WRF, os valores previstos foram comparados com os valores de

observados nas localidades de interesse. Diversas são as formas de comparação de modelos com os dados observacionais, com destaque para a comparação direta entre os dados da simulação numérica computacional com os dados das estações meteorológicas e a análise estatística de erros.

Em geral, esse processo é focado nos índices estatísticos Erro Quadrático Médio (*RMSE*) e no Erro Médio (*ME* ou *BIAS*), como mostrado em estudos de Davies et al. (1988) [68], Djemaa e Delorme (1992) [69], Pereira et al. (1996) [14], Perez et al. (1997) [70], Argiriou et al. (1999) [71], Schillings et al. (2003) [72], e Lefèvre et al. (2007) [73].

O *ME* é, dentre as consideradas aqui, a mais simples e indica o desvio sistemático das previsões, ou seja, avalia subestimação ou superestimação das estimativas em relação aos dados observados. Se for positivo, significa que os dados modelados superestimam os valores reais; enquanto que se for negativo, significa que existe uma subestimativa das estimativas em relação aos valores reais observados em superfície. O *ME* é dado por:

$$ME = \frac{1}{N} \sum_{i=1}^N (\phi_1 - \phi_o) \quad (05)$$

onde  $\phi_o$  é o valor observado da variável na estação meteorológica no *i*-ésimo instante do tempo e  $\phi_i$  é o valor da mesma variável produzida pelo modelo de rede neural para o mesmo instante de tempo da observação. O valor *N* é o número total de dados na série. O *ME* pode assumir qualquer valor real e tem a mesma unidade da variável em análise. O valor desejado para *ME* é próximo de zero.

O Erro Quadrático Médio (*RMSE*) é dado pela soma dos quadrados das diferenças entre os resultados do modelo (WRF ou RNA) e as observações nas estações meteorológica:

$$RMSE = \left[ \frac{1}{N} \sum_{i=1}^N (\phi_1 - \phi_o)^2 \right]^{1/2} \quad (06)$$

O RMSE pode assumir qualquer valor positivo e tem a mesma unidade de medida da variável em estudo. Quanto mais próximo do valor nulo estiver o *RMSE*, maior a confiabilidade das estimativas fornecidas pelo modelo.

O índice de correlação de Pearson ( $r$ ) é uma medida adimensional e, por sua vez, permite uma interpretação da relação linear entre as observações e as previsões fornecidas pelos modelos RNA's:

$$r = \frac{\sum(\phi_1 - \bar{\phi}_1)(\phi_0 - \bar{\phi}_0)}{\sqrt{[\sum(\phi_1 - \bar{\phi}_1)^2][\sum(\phi_0 - \bar{\phi}_0)^2]}} \quad (07)$$

onde  $\bar{\phi}_1$  e  $\bar{\phi}_0$  são as médias das previsões e observações. Matematicamente, o fator de correlação pode variar de -1 a 1, mas seu valor para previsão perfeita é 1. Por ser independente da escala e por não levar em conta o viés da previsão é possível encontrar uma correlação elevada para uma previsão com alto viés. O valor de um coeficiente de correlação não é garantia de haver uma relação matemática linear entre as variáveis correlacionadas. Neste trabalho, optou-se pela utilização da análise de correlação em %, sendo assim,  $r = 100\%$  representa a condição ideal, em que os dados previstos se correlacionam positivamente aos dados observados.

## 5. Resultados

### 5.1 Seleção das Estações Meteorológicas

No intuito de minimizar o tempo computacional foram escolhidos três períodos para a avaliação do modelo WRF em simular/prever a irradiância solar no Sudeste do Brasil, sendo eles fevereiro, junho e outubro. Esses meses representam o fim do período chuvoso, o período seco e o início do período chuvoso, respectivamente.

A estação de verão é, onde o mês de fevereiro está inserido, é caracterizada, pela ocorrência de mudanças rápidas nas condições diárias do tempo, com chuvas de curta duração e forte intensidade, principalmente no período da tarde. Considerando o aumento da temperatura do ar sobre o

continente, estas chuvas são acompanhadas por trovoadas e rajadas de vento, em particular no Sudeste, onde se encontram os maiores totais anuais de chuva, com valores médios superiores a 600 mm. Estas chuvas podem estar associadas à passagem de sistemas frontais e à formação do sistema meteorológico conhecido por Zona de Convergência do Atlântico Sul (ZCAS), cuja principal característica é a ocorrência de chuvas por vários dias.

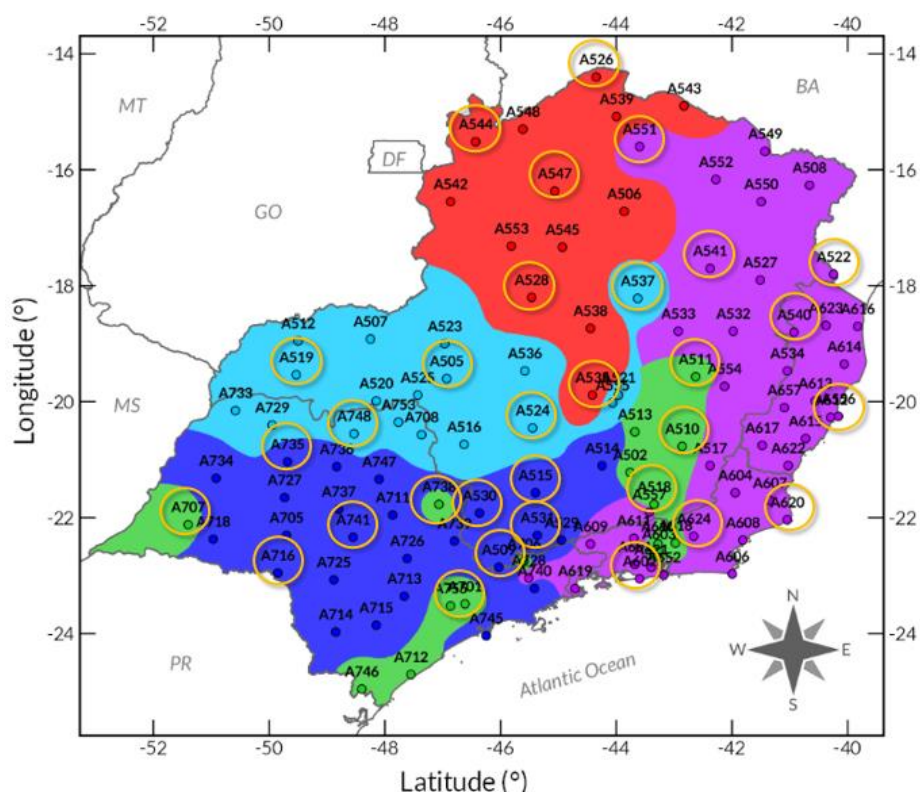
Junho é o mês de transição entre o outono e inverno, em que se verificam características de ambas as estações. É caracterizado por mudanças rápidas nas condições de tempo, maior frequência de nevoeiros e registros de geadas em locais serranos da Região Sudeste. As temperaturas tornam-se mais amenas devido à entrada de massas de ar frio, com temperaturas mínimas que variam entre 12°C a 18°C. Nestas mesmas áreas, as temperaturas máximas oscilam entre 18°C e 28°C. Nas Regiões Sudeste e Centro-Oeste, este trimestre é considerado o menos chuvoso do ano no que se refere a distribuição de chuvas. Há ocorrência de alto índice da umidade relativa do ar, cujos valores alcançam até 98% no período da manhã. O contrário ocorre no período da tarde, quando o índice da umidade relativa do ar diminui consideravelmente, chegando a registrar valores de até 40%.

Com a chegada da primavera em outubro, há uma mudança no regime de chuvas e temperaturas na maior parte do Brasil. Na região Sudeste, as chuvas passam a ser mais intensas e frequentes, marcando o período de transição entre a estação seca e a estação chuvosa. No litoral sul paulista, o período chuvoso começa em setembro, enquanto no restante da Região Sudeste, o período se inicia no final de outubro. Há aumento do calor e da umidade que se intensificam gradativamente no decorrer desta estação.

Das 116 estações meteorológicas existentes no Sudeste, foram escolhidas 31 de forma aleatória para apresentação dos resultados. Na **Tabela 2** é possível visualizar as estações selecionadas para compor a base de dados deste estudo, bem como a média mensal de radiação solar global, em W/m<sup>2</sup>. Na **Figura 7**, pode-se visualizar essas estações selecionadas distribuídas geograficamente.

**Tabela 2.** Estações meteorológicas utilizadas para o emprego da metodologia de redes neurais artificiais em cada uma das regiões homogêneas apresentadas. As três colunas a direita apresentam a média de irradiância solar incidente na superfície nos três meses de estudo.

Região Homogênea	Estações	Média Mensal de Irradiância Solar (W/m <sup>2</sup> )		
		FEV	JUN	OUT
Região 1	A526	644,98	467,67	520,71
	A528	554,95	406,16	475,22
	A535	566,79	415,87	414,87
	A544	594,15	450,61	475,25
	A547	604,04	454,67	497,82
Região 2	A522	597,66	309,48	397,01
	A540	478,32	339,02	481,70
	A541	489,60	344,30	395,98
	A551	545,56	355,04	419,56
	A556	447,75	298,32	390,33
	A602	484,21	287,13	418,44
	A620	552,00	361,96	437,98
	A624	457,52	281,17	340,56
Região 3	A505	459,85	372,23	449,81
	A519	391,12	375,39	494,18
	A524	488,11	354,01	410,53
	A537	484,19	342,67	428,95
	A748	447,07	342,62	464,18
Região 4	A510	338,28	211,59	337,64
	A511	455,92	289,45	331,59
	A518	463,67	250,85	333,79
	A707	382,09	224,73	421,70
	A738	362,30	242,04	322,20
	A755	421,94	245,42	360,97
Região 5	A509	395,51	269,34	397,92
	A515	461,79	342,53	403,24
	A530	401,51	279,80	387,57
	A531	391,85	288,97	391,87
	A716	434,86	278,46	439,30
	A735	482,27	320,87	497,65
	A741	478,15	261,51	438,22



**Figura 7:** Estações selecionadas para composição da base de dados para etapa de treinamento da RNA e de análise dos resultados (Fonte: Modificado de Lima, F. J. L, 2015 [60]).

## 5.2 Avaliação da arquitetura da RNA

Nesta seção, será apresentada de forma sucinta, os índices de RMSE (normalizados) e R calculados a partir do conjunto de dados identificados como TESTE – dados não utilizados no treinamento ou na validação da RNA, para cada estação de cada Região Homogênea, mensalmente. Por se tratar de um conjunto de dados muito grande, serão apresentados apenas os resultados que se destacaram positivamente.

Conforme descrito no item 5.3.3.1, nesse trabalho foi utilizada a rede com configuração de duas camadas ocultas e número fixo de nodes (RNA-10-[20-10]-1). Essa configuração, além de apresentar bons resultados de acordo com a literatura, reduz o tempo computacional em relação as configurações com uma cada oculta e número variável de nodes. Isso ocorre devido ao fato de que em cada estação, a rede foi treinada 100 vezes, sendo escolhida e


salva a RNA que apresentou os menores desvios entre as 100 na etapa de validação.

A variação do RMSE e R por Região Homogênea neste mesmo mês, pode ser observada na **Tabela 3.1**. É possível observar que a região que apresentou melhores resultados de RMSE e R foi a região 1, que variou de 0,07 a 0,18 e 89% a 95% respectivamente, com destaque para a estação A535 que demonstrou o menor valor de RMSE e o maior valor de R dentro da sua Região Homogênea.

**Tabela 3.1:** Valores máximos e mínimos de RMSE e de R% para cada uma das cinco regiões homogêneas no mês de fevereiro.

Região	Variação RMSE	Variação R
1	0,07- 0,18	89% - 95%
2	0,05 – 0,30	81% – 97%
3	0,17 - 0,42	76% – 91%
4	0,16 – 0,26	84% - 92%
5	0,16 – 0,40	84% - 94%

Na **Figura 8.1**, são apresentados, os gráficos de dispersão entre os dados de teste e os dados alvos, das estações com melhor e pior valores de R. Como citado anteriormente, a estação que se destacou positivamente foi a A535 da região 1. Em contrapartida, a estação que se destacou negativamente no teste da RNA foi a A524, com correlação de 76%.




**Figura 8.1:** Gráficos de dispersão entre os dados de teste e dados alvos das estações A535 (esquerda) e A524 (direita) no mês de fevereiro.

No mês de junho, a variação do RMSE e R por Região Homogênea neste mesmo mês, pode ser observada na **Tabela 3.2**. É possível observar que a região que apresentou melhores resultados de RMSE e R foi novamente a região 01, que variou de 0,05 a 0,19 e 90 a 97% respectivamente, com destaque para a estação a A544 que demonstrou o menor valor de RMSE e o maior valor de R dentro da sua Região Homogênea.

**Tabela 3.2:** Valores máximos e mínimos de RMSE e de R% para cada uma das cinco regiões homogêneas no mês de junho.

Região	Variação RMSE	Variação R
1	0,05 - 0,19	90% - 97%
2	0,06 – 0,29	87% - 96%
3	0,08 – 0,25	89% - 96%
4	0,08 – 0,38	80% - 97%
5	0,14 – 0,20	90% - 95%

O gráfico de dispersão similar ao apresentado do mês anterior foi reproduzido para junho, representando positivamente a estação A544. Nesse mês, a estação a qual a rede neural possuiu menor desempenho foi a A518 da região 4, com R de 80%. Os gráficos de dispersão das duas estações são apresentados na **Figura 8.2**.






**Figura 8.2:** Gráficos de dispersão entre os dados de teste e dados alvos das estações A544 (esquerda) e A518 (direita) no mês de junho.

No mês de outubro, a variação do RMSE e R por Região Homogênea neste mesmo mês, pode ser observada na **Tabela 3.3**. É possível observar que a região que apresentou melhores resultados de RMSE e R foi novamente a região 01, que variou de 0,11 a 0,19 e 86 a 95% respectivamente, com destaque para a estação A526 que demonstrou o menor valor de RMSE e o maior valor de R dentro da sua Região Homogênea.

**Tabela 3.3:** Valores máximos e mínimos de RMSE e de R% para cada uma das cinco regiões homogêneas no mês de outubro.

Região	Variação RMSE	Variação R
1	0,11 – 0,19	86% - 95%
2	0,08 – 0,37	83% - 97%
3	0,12 – 0,28	84% - 94%
4	0,16 – 0,27	85% - 91%
5	0,08 – 0,45	75% - 96%

O gráfico de dispersão para demonstrar o melhor e o pior desempenho na fase de teste da RNA para o mês de outubro está apresentado na **Figura 8.3** que permite observar a estação A526 com o melhor resultado e a estação A530 com menor desempenho, apresentando R de 75%.



**Figura 8.3:** Gráficos de dispersão entre os dados de teste e dados alvos das estações A526 (esquerda) e A530 (direita) no mês de outubro.

É possível observar, de modo geral, que os melhores resultados na fase de teste da RNA foram encontrados na Região 01, pois foi onde ocorreu a menor variação do RMSE e do R entre os dados de saída da RNA e os dados alvos da estação meteorológica. Além disso, apenas as Regiões 03 e 05 apresentaram valores de R inferiores à 80%, embora todas as regiões tenham apresentado valores pontuais de RMSE acima de 0,30 para todos os diferentes meses, com exceção da Região 01. Vale ressaltar, no entanto, que as médias de RMSE e R para cada região mensalmente não tiveram diferenças significativas quando comparadas umas às outras, como pode ser visto na **Tabela 4**.

**Tabela 4:** Médias de RMSE e R% para a fase de teste da RNA, por Região Homogênea para os três meses: fevereiro, junho e outubro.

Região Homogênea	FEV		JUN		OUT	
	RMSE	R%	RMSE	R%	RMSE	R%
1	0,12	92	0,10	95	0,15	92
2	0,15	91	0,16	93	0,19	89
3	0,27	85	0,13	94	0,19	89
4	0,22	89	0,21	90	0,24	88
5	0,24	82	0,16	92	0,24	88

### 5.3 Análise da irradiância solar prevista pelo WRF e ajustada pela RNA

Previsões de 24 horas foram realizadas para os meses de fevereiro, junho e outubro do ano de 2013, pois são os meses que apresentam maior incidência de irradiação solar. Tais simulações tiveram como objetivo avaliar a capacidade do modelo WRF em prever esse parâmetro e os dados resultantes dessas simulações foram fornecidos por Lima et. al., 2018 [60]. Como mencionado nos capítulos anteriores, os modelos numéricos possuem um conhecido viés na previsão de radiação solar incidente na superfície. Este foi

um dos fatores que motivaram a realização desse trabalho, uma vez que refinamentos e a obtenção de previsões com menores erros são necessários para diversas aplicações.


Uma vez que foram definidos os preditores, a arquitetura da rede e a configuração da RNA pode-se dizer que a metodologia de refinamento estatístico de irradiância solar por RNAs está completa. Sua aplicação se deu sobre as 31 estações selecionadas, divididas em 5 regiões, para as quais foram realizados 100 treinamentos em cada e foi salva a RNA com menor erro entre as 100.

Nesta seção, serão apresentados os resultados das previsões utilizando os modelos WRF e RNA. Uma avaliação da previsão de irradiância solar dada pelo modelo WRF contra os dados observacionais das estações meteorológicas, são apresentadas, sendo quantificados o BIAS, RMSE e R. Também é feita uma avaliação dos dados de irradiância solar ajustados pela RNA, contra os dados observacionais das estações meteorológicas, quantificando o ME, RMSE e R. Nesta seção, as análises são realizadas para as cinco regiões homogêneas e para todas as estações selecionadas em cada uma dessas regiões, a fim de entender como o ajuste dos dados de previsão do WRF, feito com auxílio da RNA, se comporta nas diferentes regiões e estações do ano.

Devido a grande quantidade de informações, são apresentadas nas Tabelas apenas as estações com melhores desempenhos. Nos gráficos de dispersão são apresentados apenas os padrões mais significativos das previsões efetuadas pelo WRF e pela RNA.

#### 5.3.1 Região Homogênea 1

Os parâmetros de avaliação das previsões analisadas na Região 1 são apresentados na **Figura 9.1.1**, em que foram mostrados os valores de BIAS, RMSE e R para as previsões dos modelos WRF e RNA, para os meses de fevereiro, junho e outubro.



**Figura 9.1.1:** Parâmetros de avaliação das previsões realizadas pelo WRF e pela RNA, para as estações A526, A528, A535, A544 e A547 da Região Homogênea 1. Os valores de RMSE e BIAS estão em  $W/m^2$ .

É possível verificar nos gráficos que qualquer das previsões derivadas do modelo WRF, independente do mês, sofrem redução do BIAS e RMSE, bem como aumento dos coeficientes de correlação R, para todas as estações da Região 1. Como observado, os resultados ajustados pela RNA possuem desempenhos superiores aos observados pelo modelo WRF, quando comparados aos dados de superfície das estações.


Na **Tabela 5.1**, tem-se um resumo estatístico dos índices calculados para a Região 1. É realizada uma comparação quantitativa que evidencia a superioridade dos resultados da RNA frente aos dados de previsão do modelo WRF. Enquanto o RMSE para o modelo WRF é de aproximadamente 12,04, 6,27 e 10,95 W/m<sup>2</sup> para fevereiro, junho e outubro, respectivamente, na estação A528, os dados de irradiância solar simulados pelo WRF, quando ajustados pelas RNAs, apresentam RMSE de ordem de 6,77, 3,15 e 5,06 W/m<sup>2</sup>, para fevereiro, junho e outubro, respectivamente, revelando uma redução significativa dos erros apresentados pela irradiância solar do modelo WRF. O mesmo ocorre para a estação A547 onde os resultados de RMSE do modelo WRF durante os meses de fevereiro, junho e outubro são de, respectivamente, 9,72, 8,99 e 12,16 W/m<sup>2</sup>, enquanto para a RNA, os resultados de RMSE correspondentes são 5,51, 2,99 e 5,64 W/m<sup>2</sup>.

**Tabela 4:** Resumo estatístico dos índices calculados para as estações A528 e A547, pertencentes à Região Homogênea 1. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

Estações	Meses	Erros					
		R% WRF	R% RNA	RMSE WRF	RMSE RNA	BIAS WRF	BIAS RNA
A528	Fev	80,00	93,00	12,04	6,77	36,47	2,39
	Jun	90,00	97,00	6,27	3,15	15,80	1,82
	Out	83,00	96,00	10,95	5,06	67,06	-4,47
A547	Fev	87,00	96,00	9,72	5,51	31,74	-2,92
	Jun	80,00	98,00	8,99	2,99	-10,12	-1,36
	Out	79,00	95,00	12,16	5,64	51,53	-3,18

Conforme dito anteriormente, devido à enorme quantidade de informação, optou-se por mostrar os diagramas de dispersão para as previsões dos modelos WRF e RNA apenas de uma estação para cada Região Homogênea. Em todos os diagramas de dispersão apresentados, as linhas


diagonais que passam pela origem dos gráficos representam os casos ideais, isto é, os casos em que as previsões seriam perfeitas, assumindo o mesmo valor das observações nas estações meteorológicas. Na **Figura 9.1.2**, é apresentado o gráfico de dispersão entre o modelo WRF x dados de superfície, bem como entre a RNA x dados de superfície, do mês de junho para a estação A547, pois apresentaram maior aumento da correlação, de 18%, quando comparados os dados de saída do WRF e da RNA.



**Figura 9.1.2:** Gráficos de dispersão entre os dados de Radiação Global ( $\text{W/m}^2$ ) produzidos por WRF e pela RNA *versus* os dados de superfície da Estação A547, referente ao mês de junho.

### 5.3.2 Região Homogênea 2

Verifica-se na **Figura 9.2.1** que o desempenho da RNA apresentou uma melhora significativa dos índices estatísticos apresentados pelo WRF em todas as estações de R2.



**Figura 9.2.1:** Parâmetros de avaliação das previsões realizadas pelo WRF e pela RNA, para as estações A522, A540, A541, A551, A556, A602, A620 e A624 da Região Homogênea 2. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

É possível verificar nos gráficos que qualquer das previsões derivadas do modelo WRF, independente do mês, sofrem redução do BIAS e RMSE, bem como aumento dos coeficientes de correlação R, para todas as estações da Região 2. Observa-se que os valores de BIAS do WRF foram bem altos, e a RNA proporcionou uma melhora significativa desses valores, como por exemplo na estação A624 em fevereiro, a RNA reduziu o BIAS de 128,45 para -2,20 W/m<sup>2</sup>, e a alta redução se repetiu na mesma estação para os outros dois meses. Na estação A556, também houve um grande decréscimo do BIAS dos dados produzidos pela RNA em relação ao WRF, para todos os referidos meses, destacando-se o mês de outubro com redução de 175,35 para -0,14 W/m<sup>2</sup>.


Na **Tabela 5**, observa-se que o RMSE para o modelo WRF é de aproximadamente 10,62, 12,37 e 21,54 W/m<sup>2</sup> para fevereiro, junho e outubro, respectivamente, na estação A551. Os dados de irradiância solar simulados pelo WRF, quando ajustados pelas RNAs, apresentam RMSE de ordem de 4,92, 4,49 e 6,26 W/M<sup>2</sup>, para os referidos meses da mesma estação, revelando uma redução significativa dos desvios apresentados pela previsão de irradiância solar do modelo WRF. Para a estação A556, o RMSE para os resultados do modelo WRF durante os meses de fevereiro, junho e outubro são de, respectivamente, 15,12, 11,20 e 15,07 W/m<sup>2</sup>, enquanto para a RNA, os resultados de RMSE correspondentes são 6,10, 3,86 e 4,33 W/m<sup>2</sup>.

**Tabela 5:** Resumo estatístico dos índices calculados para as estações A551 e A556, pertencentes à Região Homogênea 2. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.



Estações	Meses	Erros					
		R%	R%	RMSE	RMSE	BIAS	BIAS
		WRF	RNA	WRF	RNA	WRF	RNA
A551	Fev	88,00	97,00	10,62	4,92	97,26	10,79
	Jun	72,00	94,00	12,37	4,49	123,03	-7,56
	Out	55,00	95,00	21,54	6,26	100,11	-5,20
A556	Fev	76,00	92,00	15,12	6,10	163,25	6,40
	Jun	73,00	94,00	11,20	3,86	110,60	-0,08
	Out	78,00	97,00	15,07	4,33	175,35	-0,14


Os gráficos de dispersão entre o modelo WRF x dados de superfície, bem como entre a RNA x dados de superfície, do mês de outubro para a estação A551 é apresentado na **Figura 9.2.2**, uma vez que o ajuste na correlação proporcionado pela RNA em relação ao WRF foi de 40%.




**Figura 9.2.2:** Gráficos de dispersão entre os dados de Radiação Global ( $\text{W/m}^2$ ) produzidos por WRF e pela RNA *versus* os dados de superfície da Estação A551, referente ao mês de Outubro.

### 5.3.3 Região Homogênea 3

Na **Figura 9.3.1**, observa-se que qualquer uma das previsões, seja ela no mês de fevereiro, junho ou outubro, derivadas da RNA promovem remoção do RMSE e BIAS, bem como o aumento do coeficiente de correlação, para todas as estações de R3.





**Figura 9.3.1:** Parâmetros de avaliação das previsões realizadas pelo WRF e pela RNA, para as estações A505, A519, A524, A537, A556 e A748 da Região Homogênea 3. Os valores de RMSE e BIAS estão em W/m².


Observa-se que os valores de BIAS do WRF foram bem altos, e a RNA proporcionou uma melhora significativa desses valores, como por exemplo na estação A519 em fevereiro, a RNA reduziu o BIAS de 133,29 para -2,38 W/m², e a alta redução se repetiu na mesma estação para os outros dois meses. Na estação A524, também houve um grande decréscimo do BIAS dos dados produzidos pela RNA em relação ao WRF, para todos os referidos meses, destacando-se o mês de outubro com redução de 90,21 para 1,58 W/m².


Na **Tabela 6**, observa-se que o RMSE para o modelo WRF é de 20,40, 7,68 e 12,24 W/m² para fevereiro, junho e outubro, respectivamente, na estação A519. Os dados de irradiância solar simulados pelo WRF, quando ajustados pelas RNAs, apresentam RMSE de ordem de 8,25, 2,93 e 5,06 W/m², para os referidos meses da mesma estação, comprovando-se a importância do uso do modelo de RNA para aumento da confiabilidade das previsões fornecidas pelo WRF. Para a estação A537, o RMSE para os resultados do modelo WRF durante os meses de fevereiro, junho e outubro são de, respectivamente, 12,67, 11,03 e 13,71 W/m², enquanto para a RNA, os resultados de RMSE correspondentes são 6,45, 4,78 e 6,20 W/m².

**Tabela 6:** Resumo estatístico dos índices calculados para as estações A519 e A537, pertencentes à Região Homogênea 3. Os valores de RMSE e BIAS estão em  $W/m^2$ .

Estações	Meses	Erros					
		R%	R%	RMSE	RMSE	BIAS	BIAS
		WRF	RNA	WRF	RNA	WRF	RNA
A519	Fev	65,00	90,00	20,40	8,25	133,29	-2,38
	Jun	86,00	97,00	7,68	2,93	39,00	0,65
	Out	79,00	95,00	12,24	5,06	88,10	-0,21
A537	Fev	81,00	93,00	12,67	6,45	68,50	-2,00
	Jun	71,00	94,00	11,03	4,78	51,58	-15,98
	Out	73,00	94,00	13,71	6,20	35,28	2,53

Os gráficos de dispersão entre o modelo WRF x dados de superfície, bem como entre a RNA x dados de superfície, do mês de fevereiro para a estação A551 são apresentados na **Figura 9.3.2**, uma vez que o ajuste na correlação proporcionado pela RNA em relação ao WRF foi de 25%.






**Figura 9.3.2:** Gráficos de dispersão entre os dados de Irradiância Solar ( $\text{W/m}^2$ ) produzidos por WRF e pela RNA *versus* os dados de superfície da Estação A519, referente ao mês de Fevereiro.

#### 5.3.4 Região Homogênea 4

Verifica-se na **Figura 9.4.1** e **Tabela 7** que o desempenho da RNA apresentou uma melhora significativa em relação ao WRF, em todas as estações meteorológicas e períodos analisados. Os coeficientes de correlação e os desvios médios para a RNA e o WRF apresentaram diferenças consideráveis entre si.



**Figura 9.4.1:** Parâmetros de avaliação das previsões realizadas pelo WRF e pela RNA, para as estações A510, A511, A518, A707, A738 e A755 da Região Homogênea 4.

Essa região, especificamente, apresentou os valores de BIAS e RMSE mais altos que as demais regiões em todos os meses, como pode ser visto nos gráficos da **Figura 9.4.1**. No entanto, mesmo com os desvios elevados, a RNA apresentou um desempenho bastante satisfatório e superior ao modelo WRF, reduzindo os erros significativamente e aumentando a correlação entre valores previstos e observados.


Para a estação A510, a RNA reduziu o BIAS de 230,20 para 5,04 W/m<sup>2</sup> em fevereiro e, em junho, de 176,88 para -0,33 W/m<sup>2</sup>. Em outubro, o BIAS passou de 160,03 para 0,78 W/m<sup>2</sup>. Na estação A738, também houve um grande decréscimo do BIAS produzidos pela RNA em relação ao WRF, para todos os referidos meses, destacando-se o mês de outubro com redução de 197,39 para -5,52 W/m<sup>2</sup>.

Na **Tabela 7**, observa-se na estação A510 que o RMSE das estimativas produzidas pelo modelo WRF é de 17,33, 10,36 e 16,50 W/m<sup>2</sup> para fevereiro, junho e outubro, respectivamente. As previsões de irradiância solar com uso das RNAs apresentam RMSE de ordem de 4,06, 3,52 e 6,83 W/m<sup>2</sup>, para os referidos meses da mesma estação, comprovando-se a superioridade do modelo de RNA frente ao WRF. Para a estação A 707, o desvio RMSE para os resultados do modelo WRF durante os meses de fevereiro, junho e outubro são de, respectivamente, 16,68, 13,06 e 14,69 W/m<sup>2</sup>, enquanto para a RNA, os resultados de RMSE correspondentes são 6,18, 2,91 e 5,03 W/m<sup>2</sup>.

**Tabela 7:** Resumo estatístico dos índices calculados para as estações A510 e A707, pertencentes à Região Homogênea 4. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

Estações	Meses	Erros					
		R%	R%	RMSE	RMSE	BIAS	BIAS
		WRF	RNA	WRF	RNA	WRF	RNA
A510	Fev	80,00	95,00	17,33	4,06	230,20	5,04
	Jun	77,00	96,00	10,36	3,52	98,43	-3,37
	Out	67,00	89,00	16,50	6,83	170,50	-5,58
A707	Fev	60,00	93,00	16,68	6,18	131,48	5,25
	Jun	56,00	97,00	13,06	2,91	102,54	-1,79
	Out	75,00	95,00	14,69	5,03	152,87	-1,10

Os gráficos de dispersão entre o modelo WRF x dados de superfície, bem como entre a RNA x dados de superfície, do mês de junho para a estação A707 é apresentado na **Figura 9.4.2**, uma vez que o ajuste na correlação proporcionado pela RNA em relação ao WRF foi de 41%, o maior ganho de desempenho proporcionado pelo uso de RNA entre todas as regiões.




**Figura 9.4.2:** Gráficos de dispersão entre os dados de Irradiância Solar( $\text{W/m}^2$ ) produzidos por WRF e pela RNA *versus* os dados de superfície da Estação A707, referente ao mês de Junho.


### 5.3.5 Região Homogênea 5

É possível verificar nos gráficos da **Figura 9.5.1** que qualquer das previsões derivadas do modelo WRF, independente do mês, apresentam



desvios BIAS e RMSE, maiores e coeficientes de correlação R inferiores em do que os mesmos índices apresentados pelas estimativas produzidas pelas RNA em todas as estações da Região 5. Como observado, os resultados ajustados pela RNA possuem desempenhos superiores aos observados pelo modelo WRF, quando comparados aos dados de superfície das estações.





**Figura 9.5.1:** Parâmetros de avaliação das previsões realizadas pelo WRF e pela RNA, para as estações A509, A515, A530, A531, A716, A735 e A741 da Região Homogênea 4.


Para a estação A509, em fevereiro, a RNA reduziu o BIAS de 129,31 para -4,04 W/m<sup>2</sup>. Para a estação A741, também houve um grande decréscimo do BIAS com uso da RNA para prever a irradiância solar na superfície em todos os referidos meses, destacando-se o mês de outubro com redução de 97,05 para 0,62 W/m<sup>2</sup>.


A **Tabela 8**, mostra o desvio RMSE para o modelo WRF é de 14,70, 10,15 e 13,45 W/m<sup>2</sup> para fevereiro, junho e outubro, respectivamente, na estação A530. Na mesma estação meteorológica, a previsão de irradiância solar obtida com a RNA apresenta RMSE de ordem de 7,82, 3,91 e 5,72 W/m<sup>2</sup>, para os referidos meses comprovando a superioridade da RNA frente ao WRF. Para a estação A716, o desvio RMSE para as previsões do modelo WRF durante os meses de fevereiro, junho e outubro são de, respectivamente, 14,95, 9,97 e 12,58 W/m<sup>2</sup>. A RNA fornece estimativas com desvios RMSE correspondentes são 7,47, 3,27 e 4,63 W/m<sup>2</sup>. Já para a estação A735, a redução do RMSE foi de 14,94, 9,63 e 12,98 para 7,84, 3,64 e 4,74 W/m<sup>2</sup> para os meses de fevereiro, junho e outubro, respectivamente.

**Tabela 8:** Resumo estatístico dos índices calculados para as estações A530, A716 e A735, pertencentes à Região Homogênea 5. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

Estações	Meses	Erros					
		R%	R%	RMSE	RMSE	BIAS	BIAS
		WRF	RNA	WRF	RNA	WRF	RNA
A530	Fev	71,00	89,00	14,70	7,82	88,29	0,88
	Jun	76,00	94,00	10,15	3,91	82,35	-1,01
	Out	77,00	93,00	13,45	5,72	115,30	2,68
A716	Fev	65,00	90,00	14,95	7,47	58,78	-7,67
	Jun	72,00	97,00	9,97	3,27	38,56	0,46
	Out	79,00	96,00	12,58	4,63	101,97	-6,03
A735	Fev	65,00	90,00	14,94	7,84	21,37	-21,83
	Jun	76,00	95,00	9,63	3,64	66,78	-1,46
	Out	77,00	96,00	12,98	4,74	85,59	-7,02

Os gráficos de dispersão entre o modelo WRF x dados de superfície, bem como entre a RNA x dados de superfície para a estação A716 no mês de junho é apresentado na **Figura 9.5.2**, uma vez que o ajuste na correlação proporcionado pela RNA em relação ao WRF foi de 25%. Os dados dessa estação para esse mês tiveram a correlação final de 97%.





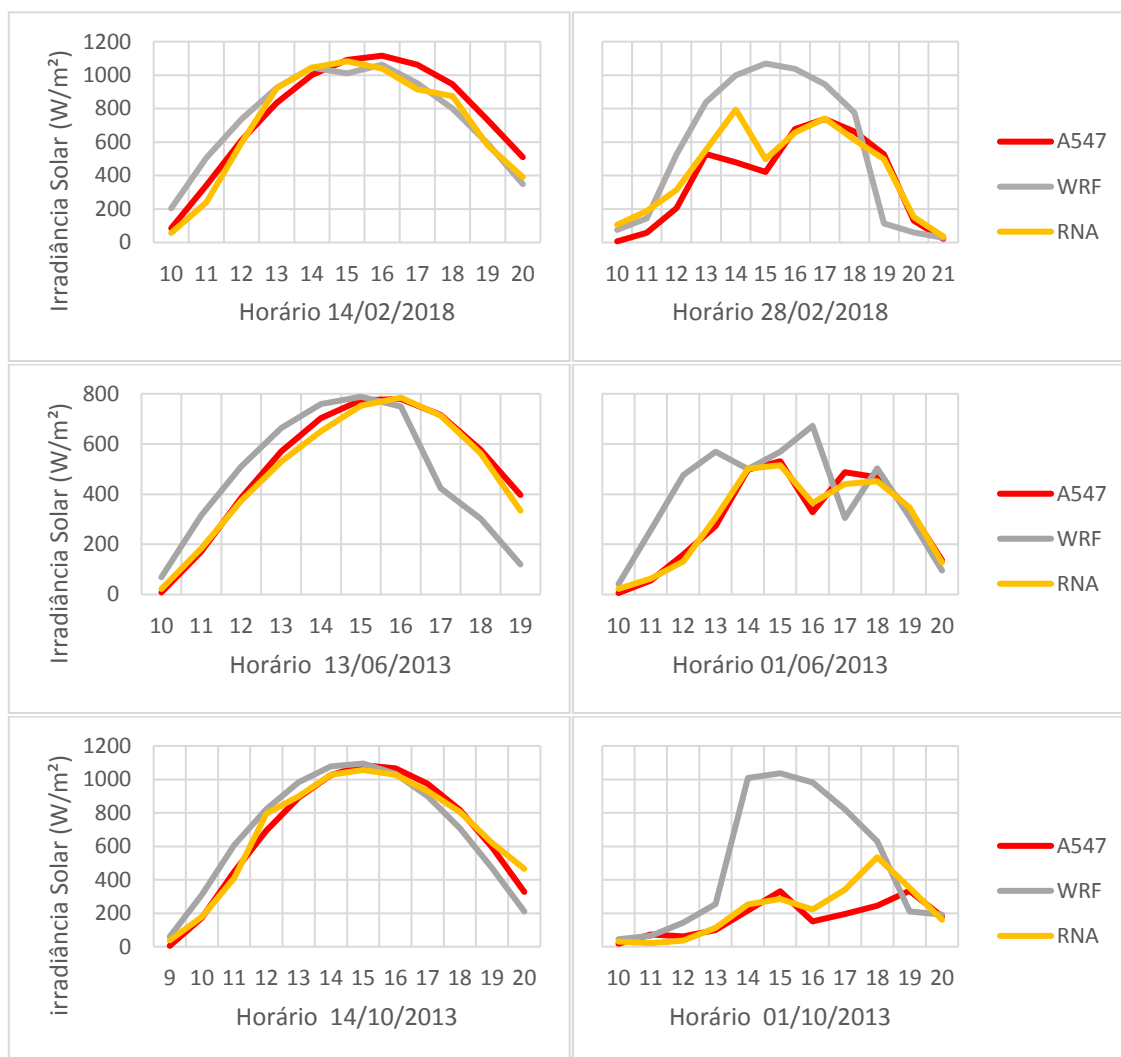
**Figura 9.5.2:** Gráficos de dispersão entre os dados de Irradiância Solar ( $\text{W/m}^2$ ) produzidos por WRF e pela RNA *versus* os dados de superfície da Estação A716, referente ao mês de Junho.

#### 5.4 Avaliação das Previsões horárias no horizonte de 24h para cada Região Homogênea.

Esta seção descreve os resultados alcançados para o desempenho da RNA em prever o ciclo diário da irradiância solar na superfície para diferentes meses do ano e condições climáticas, considerando os distintos processos meteorológicos. Uma vez que se observa condições de clima bastante diversas para os meses de fevereiro, junho e outubro, e como os sistemas meteorológicos atuantes em cada uma das áreas homogêneas podem ser bastante distintos por conta da localidade, os modelos de previsão de tempo nem sempre apresentam o mesmo desempenho na previsão de irradiância solar para todas as épocas do ano.

Devido à quantidade de dados ser muito extensa, optou-se por utilizar as mesmas estações meteorológicas que se destacaram na última seção para análise dos resultados. Serão apresentados gráficos com dados horários de irradiância para alguns dias com características distintas, visando entender como os modelos de previsão se comportam diante os diferentes processos atmosféricos.

A região onde se localiza a Estação A547 é caracterizada por temperaturas quentes, e clima semi-úmido, com 4 a 5 meses secos. Na **Figura 9.6.1**, observa-se os gráficos de irradiância solar horária em dois dias nos meses de fevereiro, junho e outubro para a estação A547, pertencente à Região Homogênea 01. Apresenta-se também a irradiância solar horária prevista pelo modelo WRF e pela RNA, para fins de comparação.

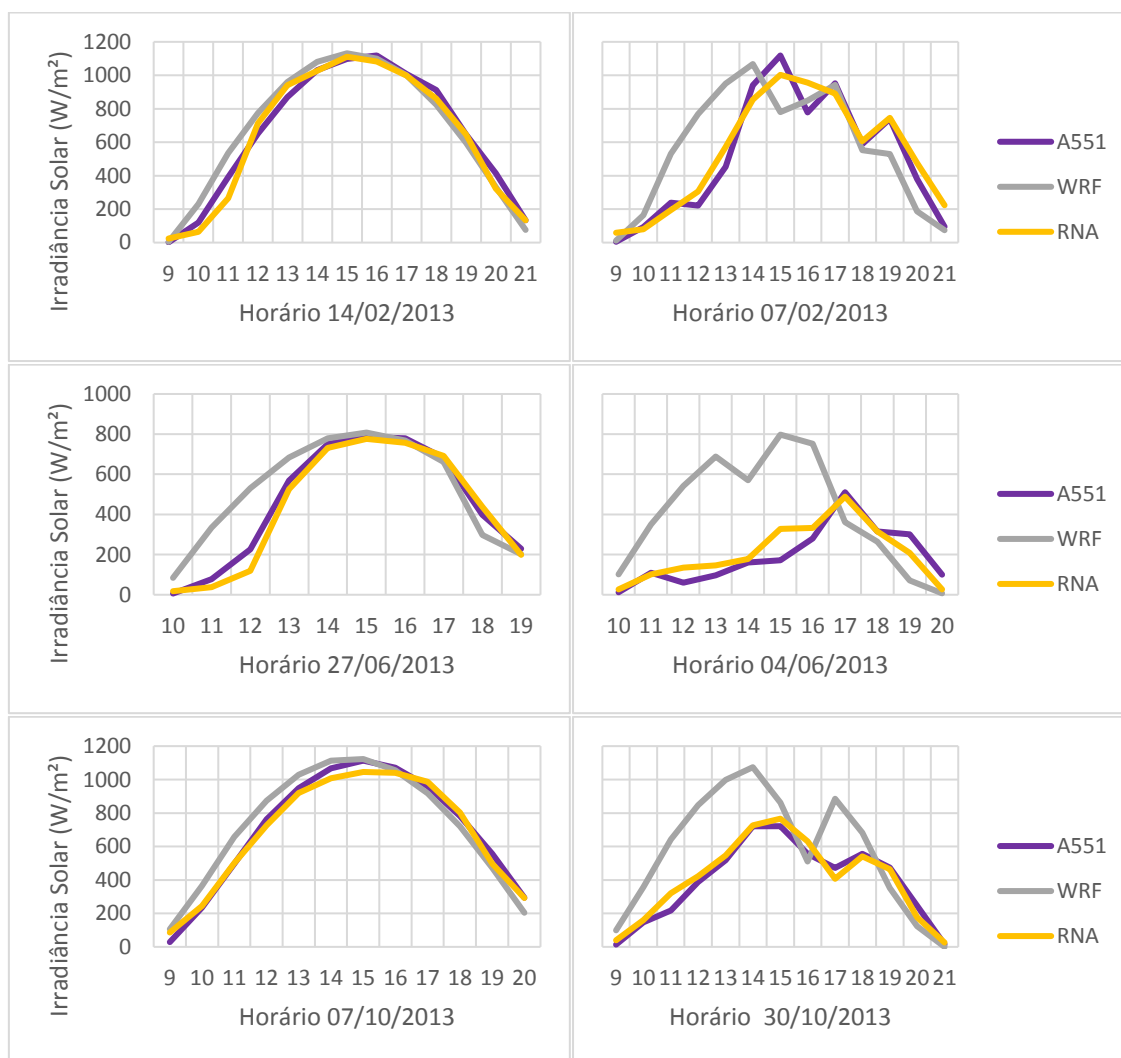


**Figura 9.6.1:** Gráficos comparativos entre os valores de irradiância solar estimados pelo WRF, pela RNA e observados na Estação A547 em dias de céu claro (lado esquerdo) e céu parcialmente encoberto (lado direito), para os três meses em estudo.

Pode-se observar que, para todos os meses, em dias de céu claro tanto o WRF quanto a RNA representam bem os dados observados na superfície, obtidos na estação A547. Porém, como era esperado e foi demonstrado nas seções anteriores, a RNA se mostra mais representativa, tanto para os dias de

céu claro quando para os dias de céu encoberto. Nos dias de céu encoberto, o WRF tende a superestimar os dados observados em superfície.

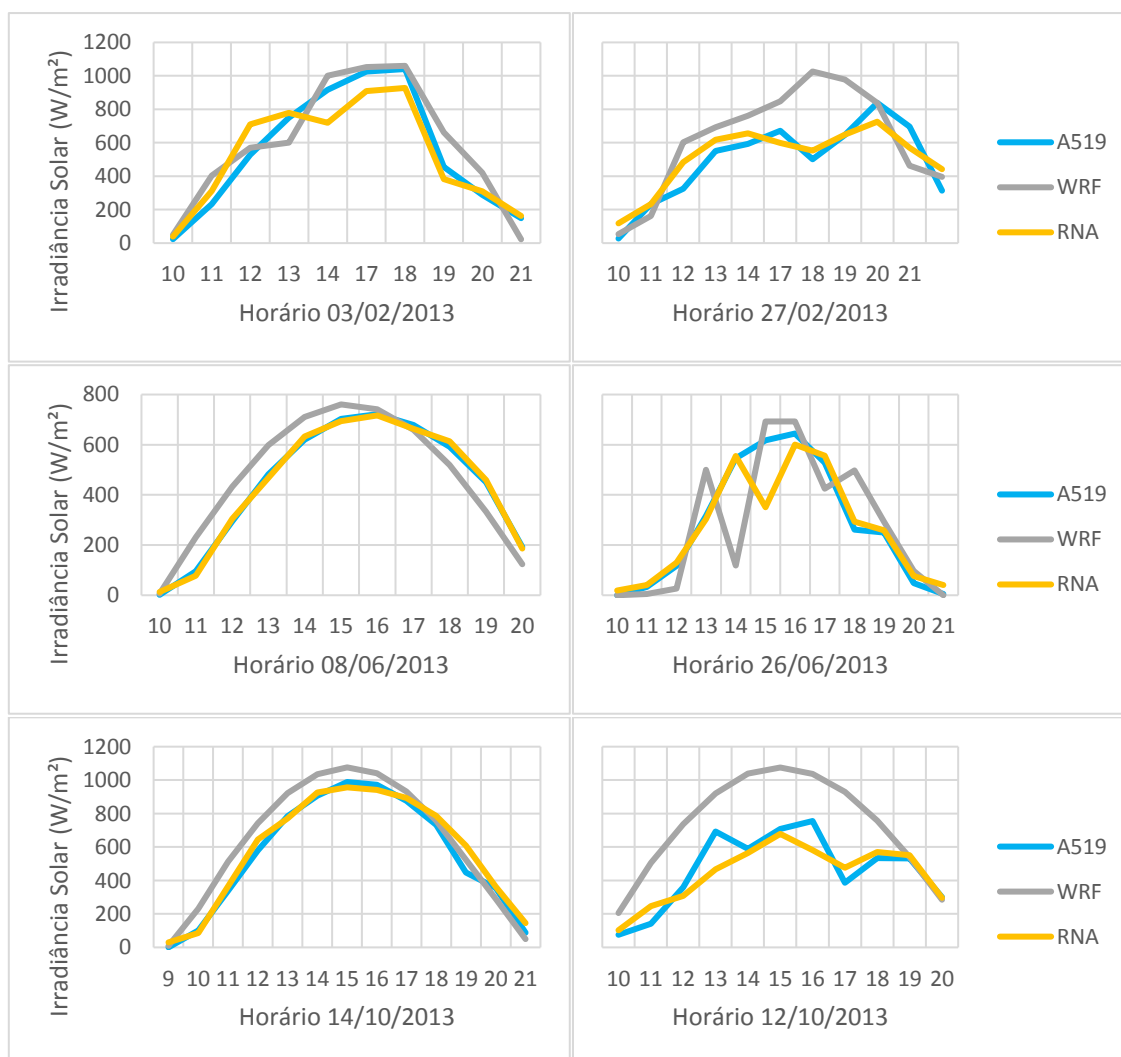
A região onde se localiza a Estação A551 também possui temperaturas quentes, porém com características típicas de clima semi-árido do sertão nordestino, com precipitação anual que não ultrapassa os 800mm de chuva e o regime pluviométrico constitui-se em longos períodos de estiagem que podem durar 5 ou 6 meses. Na **Figura 9.6.2**, observa-se os gráficos de irradiância solar horária observada, a irradiância solar horária prevista pelo modelo WRF e pela RNA, em dois dias nos meses de fevereiro, junho e outubro para a estação A551, pertencente à Região Homogênea 02.



**Figura 9.6.2:** Gráficos comparativos entre os valores de irradiância solar estimados pelo WRF, pela RNA e observados na Estação A551 em dias de céu claro (lado esquerdo) e céu parcialmente encoberto (lado direito), para os três meses em estudo.

Observa-se que, em dias de céu claro, tanto o WRF quanto a RNA representam bem os dados observados na estação A551. Contudo, a RNA se mostra mais representativa, sobretudo para os dias de céu encoberto ou parcialmente encoberto em fevereiro, junho e outubro. Assim como para a estação A547, o WRF tende a superestimar a irradiância solar na superfície em dias de céu encoberto.

A região onde se localiza a Estação A519 é caracterizada por temperaturas quentes, e clima úmido, com 3 meses secos ao ano, tendo o maior índice pluviométrico entre as duas regiões anteriormente apresentadas. Na **Figura 9.6.3**, observa-se os gráficos de irradiância solar horária observados, simulados pelo WRF e estimados pela RNA, para fins de comparação. Os gráficos seguiram os mesmos padrões das regiões anteriores, sendo agora apresentados os resultados da Região Homogênea 3, representada pela estação A519.

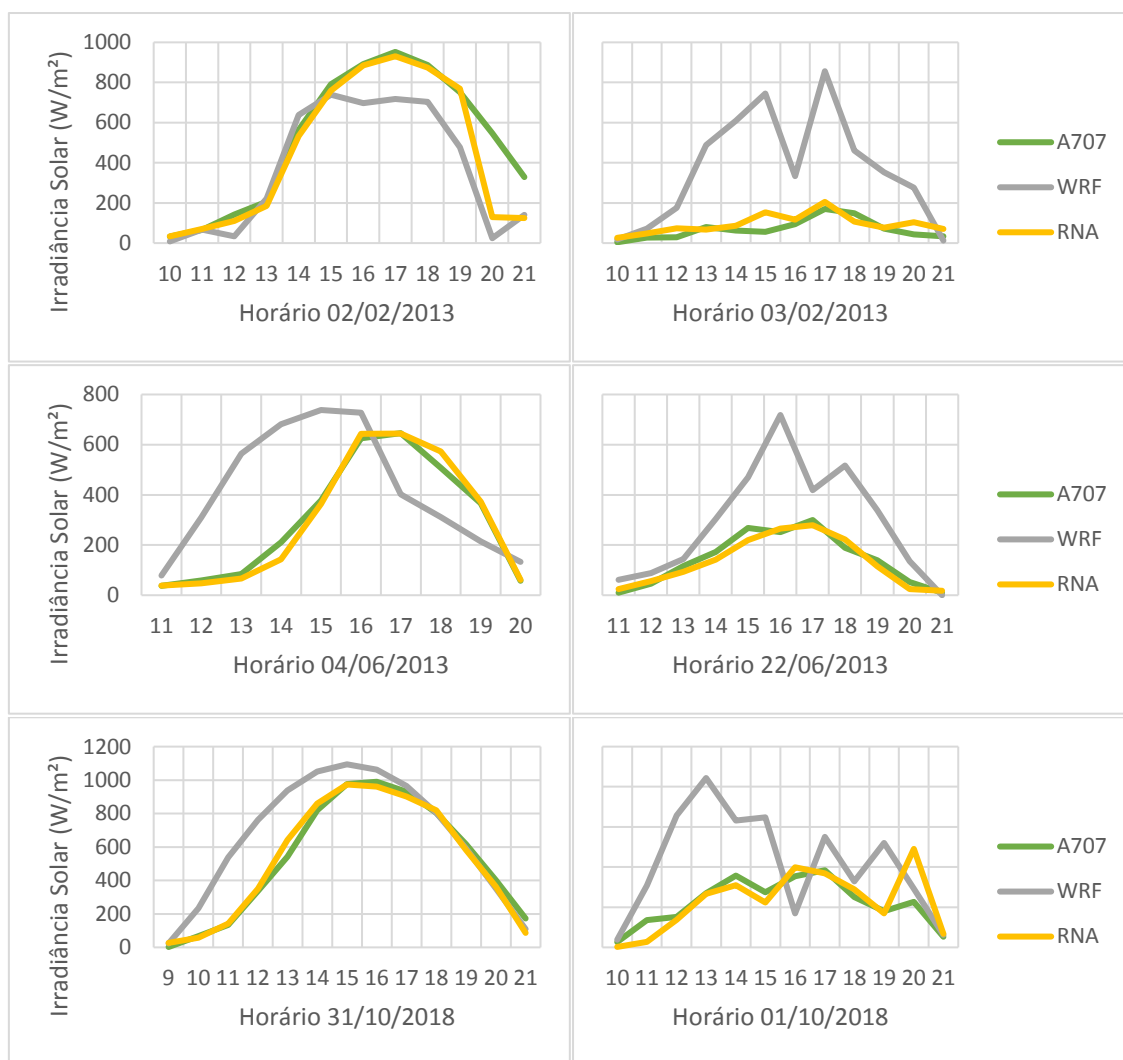


**Figura 9.6.3:** Gráficos comparativos entre os valores de irradiância Solar estimados pelo WRF, pela RNA e observados na Estação A519 em dias de céu claro (lado esquerdo) e céu parcialmente encoberto (lado direito), para os três meses em estudo.

Observa-se que, para todos os meses, em dias de céu claro tanto o WRF quanto a RNA representam bem os dados observados na superfície da A519. A RNA, como demonstrado nas seções anteriores, apresenta melhor desempenho, sobretudo para os dias de céu encoberto em fevereiro, junho e outubro, dias os quais o WRF não consegue simular tão bem observações de irradiância solar na superfície. No dia 12/10/2013, mesmo que fosse um dia de céu encoberto, o WRF demonstrou resultados de irradiância solar característicos de um dia de céu claro, ao contrário da RNA, que se aproximou mais dos dados de superfície e manteve a característica de céu encoberto.

A região onde se localiza a Estação A707, diferentemente das regiões anteriores, é uma região subquente com clima super úmido, com 3 meses secos ao ano. Ela apresenta temperaturas médias ligeiramente inferiores, pelo efeito da altitude, mas com características pluviométricas semelhantes às regiões quentes. Na **Figura 9.6.4**, observa-se os gráficos de irradiância solar horária observados, simulados pelo WRF e estimados pela RNA, para os três meses da estação A707, pertencente à Região Homogênea 04.

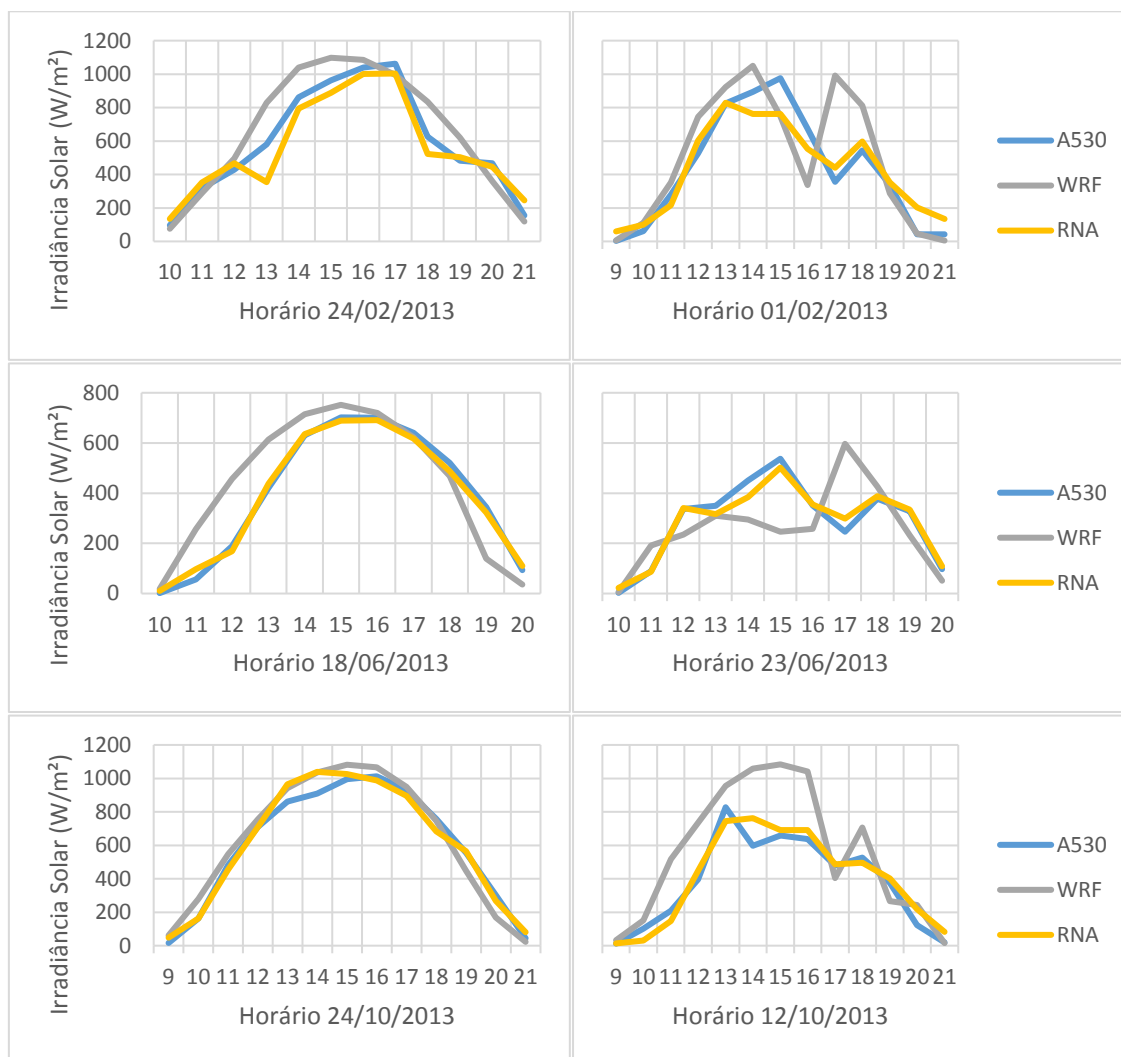




**Figura 9.6.4:** Gráficos comparativos entre os valores de irradiância solar estimados pelo WRF, pela RNA e observados na Estação A707 em dias de céu claro (lado esquerdo) e céu parcialmente encoberto (lado direito), para os três meses em estudo.

Observa-se que, mesmo em dias de céu claro o WRF não representou tão bem os dados medidos, quando comparados com as regiões anteriores. No entanto, a RNA, novamente, apresenta um excelente desempenho tanto para as condições de céu claro ou céu encoberto. Vale ressaltar que, nos dias de céu encoberto, para os três meses, os dados observados de irradiância não passaram de 384 W/m<sup>2</sup>, enquanto para os dias de céu claro, a irradiância chegou a 930,76 W/m<sup>2</sup> no mês de fevereiro. Mesmo com a alta diferença de incidência de radiação solar, a RNA teve bom desempenho, mostrando que é confiável para estimativa de dias de céu claro, de céu encoberto, e com diferentes taxas de radiação solar.

A região onde está localizada a Estação A530 é uma região considerada mesotérmica branda com clima super úmido, cujas temperaturas são mais brandas e distribuição sazonal das chuvas é mais uniforme com período seco menos prolongado. Na **Figura 9.6.5**, observa-se os gráficos de irradiância solar horária observados, simulados pelo WRF e estimados pela RNA, para os três meses da estação A530, pertencente à Região Homogênea 05.



**Figura 9.6.5:** Gráficos comparativos entre os valores de irradiância solar estimados pelo WRF, pela RNA e observados na Estação A530 em dias de céu claro (lado esquerdo) e céu parcialmente encoberto (lado direito), para os três meses em estudo.

Observa-se que, para todos os meses, em dias de céu claro tanto o WRF quanto a RNA demonstraram boa capacidade em representar dos dados medidos, exceto em alguns casos que o WRF superestimou os dados de

superfície. No entanto, a RNA, como demonstrado nas seções anteriores, apresenta melhor desempenho, para qualquer condição de nebulosidade.

No geral, os climas latitudinais na Região Sudeste, apesar de tipicamente tropicais, apresentam significativas variações térmicas e pluviométricas em grande parte explicadas pela grande extensão norte/sul que produz, à medida que a latitude aumenta, diminuição da temperatura e aumento dos totais anuais de precipitação. Além dessa diversidade, os fatores dinâmicos da atmosfera em áreas de Sudeste afetam a regularidade e a previsibilidade das condições de tempo e do clima, tanto de curto quanto de longo prazo. Sob uma aparente regularidade climática, a distribuição interanual das chuvas demonstra num período de quase 40 anos é possível observar a sucessão de anos verões e invernos secos e úmido. Mesmo com essa dificuldade, é notável que as redes neurais se mostram uma excelente alternativa para previsão da irradiância solar incidente na superfície, considerando todas as variações térmicas, pluviométricas e de insolação durante o ano.

### 5.5 Análise das previsões de irradiância solar para horizontes de 48h e 72h

Nesta seção, serão apresentadas as avaliações das previsões de até 48 e 72 horas para cada Região Homogênea, nos meses de fevereiro, junho e outubro de 2013 a fim de comparar a capacidade do modelo de mesoescala WRF em prever a irradiância solar para horizontes mais longas, em relação às previsões de até 24 horas dadas pelo mesmo modelo. Os dados resultantes das simulações realizadas pelo WRF de 48h e 72h também foram fornecidos por Lima et. al., 2018 [60].

Para ajuste dos dados de saída do WRF pelas RNAs, foi utilizada nessa etapa a melhor rede salva entre as 100 testadas para os dados das previsões de até 24 horas, conforme descrito detalhadamente nos itens 5.3.3.2 e 6.3. Optou-se por utilizar a RNA com menor erro para cada estação de cada Região Homogênea, quando treinada com dados das estimativas de até 24 horas, e avaliar se ela possui o desempenho similar para as estimativas de 48 e 72 horas. Dessa forma, seria possível utilizar a mesma rede para as três previsões

e diminuir o tempo computacional, visto que não seria necessário realizar novamente os testes para obtenção da melhor rede.

Devido à grande quantidade de informações, são apresentadas nesta seção apenas as estações com melhores desempenhos na etapa de previsão de irradiância de até 24h em cada Região Homogênea. Ou seja, serão analisados os resultados das estações detalhadas no item 6.4, sendo elas A547 (Região Homogênea 1), A551 (Região Homogênea 2) A519 (Região Homogênea 3), A707 (Região Homogênea 4) e A530 (Região Homogênea 5).

### 5.5.1 Região Homogênea 01 – A547

Na **Tabela 9.1**, pode-se visualizar o resumo estatístico dos resultados das simulações do modelo WRF, para previsões de 24, 48 e 72h, quando comparado ao desempenho das previsões realizadas pela RNA, para os mesmos horários. Foram analisados os resultados para os três meses propostos nesse estudo, fevereiro, junho e outubro da estação A547. Para cada horário, encontra-se o valor de R%, RMSE e BIAS para avaliação do desempenho do WRF e da RNA.

**Tabela 9.1:** Resumo estatístico dos índices calculados para previsões de 24h, 48h e 72h de irradiância solar na Estação A547, pertencente à Região Homogênea 01, nos meses de fevereiro, junho e outubro. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

		R%						RMSE						BIAS					
		24h		48h		72h		24h		48h		72h		24h		48h		72h	
A547	Fev	87	96	84	85	82	86	9,72	5,51	10,62	10,71	11,26	10,23	31,74	-2,92	-5,42	51,11	-21,82	50,67
	Jun	80	98	85	92	86	93	8,99	2,99	7,66	6,49	7,73	6,11	-10,12	-1,36	0,39	60,33	-10,84	53,87
	Out	79	95	77	83	78	83	12,16	5,64	12,23	10,33	12,12	10,53	51,53	-3,18	10,60	19,90	18,46	24,51

Verifica-se na **Tabela 9.1** que o desempenho do modelo WRF foi semelhante para todos os meses e para as previsões de 24, 48 e 72h. Observa-se em ambos os períodos que o modelo de RNA obteve uma redução significativa dos erros em relação às saídas do modelo WRF, exceto pelo BIAS nas previsões de 48 e 72h nos três meses, que apresentou aumento. Mesmo com aumento do BIAS para as previsões de 48h e 72h, houve aumento

significativo da correlação e redução dos índices de RMSE para as mesmas previsões, para todos os meses. Sendo assim, é possível considerar que RNA que apresentou melhor desempenho para os dados de 24h, também é aplicável as previsões de 48h e 72h.

### 5.5.2 Região Homogênea 02 – A551

Na **Tabela 9.2**, encontra-se o resumo estatístico dos resultados das simulações do modelo WRF, para previsões para os horizontes de 24, 48 e 72h, quando comparado ao desempenho das previsões realizadas pela RNA, para os mesmos horários. Também foram analisados os resultados para os meses de fevereiro, junho e outubro da estação A551. Para cada horário, encontra-se o valor de R%, RMSE e BIAS para demonstração do desempenho do WRF, seguido pelos índices estatísticos da RNA.

**Tabela 9.2:** Resumo estatístico dos índices calculados para a Estação A551, pertencente à Região Homogênea 01, para previsões de irradiância solar nos horizontes de 24h, 48h e 72h, para os meses de fevereiro, junho e outubro. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

		R%						RMSE						BIAS					
		24h		48h		72h		24h		48h		72h		24h		48h		72h	
A551	Fev	88	97	90	94	87	93	10,61	4,92	9,51	6,45	10,11	7,18	97,26	10,79	82,95	25,66	46,06	10,00
	Jun	72	94	76	80	72	73	12,37	4,49	11,67	8,39	12,01	9,85	123,03	-7,56	119,67	18,88	108,90	19,86
	Out	55	95	75	87	74	79	21,54	6,26	15,81	8,67	15,43	10,91	100,11	-5,20	108,90	19,86	160,51	-21,25

É possível observar na **Tabela 9.2** que o desempenho do modelo WRF foi semelhante para todos os meses e para as previsões de 24, 48 e 72h. Verifica-se que o modelo de RNA obteve uma redução significativa dos erros em relação às saídas do modelo WRF, com destaque para o mês de fevereiro, em que todos os resultados de correlação ficaram acima de 93%. Para previsões de até 72h o mês de junho, no entanto, o aumento da correlação não foi tão significativo, sendo de 72% do WRF e 73% da RNA, porém, os índices de RMSE e BIAS decresceram, conforme ocorreu para os dados de previsão de até 24h. No caso dessa estação, a RNA obtida no treinamento com dados de previsão de até 24h também pode ser aplicada para os dados de previsão

de 48 e 72h, visto que o seu desempenho nos três casos foi positivo, para todos os meses propostos nesse estudo.

### 5.5.3 Região Homogênea 03 – A519

Na **Tabela 9.3**, encontra-se o resumo estatístico dos resultados das simulações do modelo WRF, para previsões de irradiância solar em horizontes de 24, 48 e 72h, quando comparado ao desempenho das previsões realizadas pela RNA, para os mesmos horários. Também foram analisados os resultados para os meses de fevereiro, junho e outubro da estação A519. Para cada horário, encontra-se o valor de R%, RMSE e BIAS para demonstração do desempenho do WRF, seguido pelos índices estatísticos da RNA.

**Tabela 9.3:** Resumo estatístico dos índices calculados para a Estação A519, pertencente à Região Homogênea 03, para previsões de irradiância solar nos horizontes de 24h, 48h e 72h, para os meses de fevereiro, junho e outubro. Os valores de RMSE e BIAS estão em  $W/m^2$ .

		R%						RMSE						BIAS					
		24h		48h		72h		24h		48h		72h		24h		48h		72h	
A519	Fev	65	90	66	60	51	58	20,40	8,25	18,52	17,10	19,41	17,79	133,29	-2,38	85,98	21,35	18,89	41,17
	Jun	86	97	85	90	86	87	7,68	2,93	7,43	6,42	7,09	7,23	39,00	0,65	10,98	48,83	6,85	56,67
	Out	79	95	78	87	78	86	12,24	5,06	12,25	8,55	12,04	9,07	88,10	-0,21	55,91	18,81	38,00	35,00

Observa-se na **Tabela 9.3** que o desempenho do modelo WRF foi semelhante para todos os meses e para as previsões de 24, 48 e 72h. Quanto aos resultados obtidos pela previsão da RNA, não foram tão positivos em alguns casos, como por exemplo para a previsão de até 48h no mês de fevereiro, o qual houve redução da correlação de 66 para 60%, mesmo que tenha ocorrido redução do RMSE, de  $18,52 W/m^2$  para  $17,10 W/m^2$  e do BIAS, de  $85,98 W/m^2$  para  $21,35 W/m^2$ . O mesmo ocorre para os resultados de previsão de até 72h para o mesmo mês, com aumento de correlação de 51% para 58%. Mesmo que a correlação tenha aumentado com a previsão realizada pela RNA, 58% é considerado um valor baixo de correlação. Nesses casos do mês de fevereiro, seria importante o treinamento da RNA utilizando o método descrito em 5.3.3.2, a fim de encontrar uma rede que aumentasse

significativamente a correlação dada pelo WRF e trouxesse melhores resultados para ambas as previsões. Para os meses de junho e outubro, no entanto, os resultados de previsão de 48 e 72h foram semelhantes aos obtidos pela previsão de 24h, com destaque para o outubro.

#### 5.5.4 Região Homogênea 04 – A707

Na **Tabela 9.4**, encontra-se o resumo estatístico dos resultados das simulações do modelo WRF, para previsões de 24, 48 e 72h, quando comparado ao desempenho das previsões realizadas pela RNA, para os mesmos horários e meses, da estação A707. Para cada horário, encontra-se o valor de R%, RMSE e BIAS para demonstração do desempenho do WRF, seguido pelos índices estatísticos da RNA.

**Tabela 9.4:** Resumo estatístico dos índices calculados para a Estação A707, pertencente à Região Homogênea 04, para previsões de irradiância solar nos horizontes de 24h, 48h e 72h, para os meses de fevereiro, junho e outubro. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

		R%						RMSE						BIAS					
		24h		48h		72h		24h		48h		72h		24h		48h		72h	
A707	Fev	60	93	61	83	56	80	16,68	6,18	14,75	10,62	15,87	11,51	131,48	5,25	51,34	78,90	60,11	77,86
	Jun	56	97	64	82	59	80	13,36	2,91	11,73	8,48	12,86	8,83	102,54	-1,79	89,52	73,45	106,12	77,96
	Out	75	95	70	84	75	81	14,69	5,03	14,85	9,53	13,41	10,43	152,87	-1,10	110,85	10,71	96,32	-0,97

Observa-se na **Tabela 9.4** que o melhor desempenho do modelo WRF se encontra no mês de outubro, enquanto o pior no mês de fevereiro, para todas as previsões. A RNA, por sua vez, apresentou bons resultados para todos os meses, mas também teve melhor desempenho no mês de outubro: para previsões de 48h, houve aumento da correlação de 70 para 84%, redução do RMSE de 14,85 W/m<sup>2</sup>; para 9,53 W/m<sup>2</sup> e do BIAS de 110,85 W/m<sup>2</sup>. para 10,71 W/m<sup>2</sup>; para previsões de 72h, também houve aumento da correlação, porém o destaque maior foi para o valor de BIAS, o qual foi reduzido de 96,32 W/m<sup>2</sup>. para -0,97 W/m<sup>2</sup>. Através da análise dos índices dessa estação, foi comprovada mais uma vez a eficiência das RNA em reduzir os erros sistemáticos do WRF para previsões de 24h, 48h e 72h.

### 5.5.5 Região Homogênea 05 – A530

Na **Tabela 9.5**, encontra-se o resumo estatístico dos resultados das simulações do modelo WRF, para previsões de 24, 48 e 72h, quando comparado ao desempenho das previsões realizadas pela RNA, para os mesmos horários e meses, da estação A530. Para cada horário, encontra-se o valor de R%, RMSE e BIAS para demonstração do desempenho do WRF, seguido pelos índices estatísticos da RNA.


**Tabela 9.5:** Resumo estatístico dos índices calculados para a Estação A530, pertencente à Região Homogênea 05, para previsões de 24h, 48h e 72h, para os meses de fevereiro, junho e outubro. Os valores de RMSE e BIAS estão em W/m<sup>2</sup>.

		R%						RMSE						BIAS					
		24h		48h		72h		24h		48h		72h		24h		48h		72h	
A530	Fev	71	89	70	77	71	75	14,70	7,82	14,44	10,85	14,36	11,11	88,29	0,88	64,40	13,94	72,00	11,32
	Jun	76	94	80	82	77	78	10,15	3,91	9,53	7,48	9,64	8,37	82,35	-1,01	76,55	36,02	59,87	34,13
	Out	77	93	75	79	73	77	13,45	5,72	14,36	10,04	14,50	10,79	115,3	2,68	139	15	127,16	26,15

É possível observar na **Tabela 9.5**, que o modelo WRF apresentou bom desempenho para todas as previsões e todos os meses, com correlação superior à 70% em todos os casos. O desempenho da RNA foi satisfatório para todos os meses do estudo, também com destaque para o mês de outubro, pois obteve as melhores correlações para os dados de previsão de 48 e 72h, sendo os valores correspondentes de 79% e 77%. Os índices de RMSE também tiveram melhora em ambas as previsões. Vale ressaltar que o valor de BIAS sofreu um decréscimo significativo para esse mês, de 139 W/m<sup>2</sup> para 15 W/m<sup>2</sup> em previsões de até 48h e de 127,16 W/m<sup>2</sup> para 26,15 W/m<sup>2</sup> para previsões de até 72h, mantendo o padrão de redução encontrado para as previsões de até 24h. Nessa estação, portanto, observa-se um comportamento similar entre o desempenho do WRF e da RNA para previsões de 48h e 72h, utilizando a RNA de treinamento dos dados de previsões de até 24h, mostrando que a metodologia foi satisfatória.



Comparando os resultados de cada Região Homogênea nessa seção, é possível observar que o melhor desempenho da RNA ocorreu na estação A551 e, conforme descrito anteriormente, houve destaque para o mês de fevereiro, cuja correlação entre dados observados e obtidos pela RNA foi de 97%, 94% e 93% para, respectivamente, as previsões de 24h, 48h e 72h. Os valores de BIAS foram de 10,99 W/m<sup>2</sup>, 25,66 W/m<sup>2</sup> e 10 W/m<sup>2</sup> para as respectivas previsões, enquanto os valores de RMSE foram de 4,92 W/m<sup>2</sup>, 6,45 W/m<sup>2</sup> e 7,18 W/m<sup>2</sup> para as respectivas previsões. Na **Figura 10**, verifica-se o comportamento das previsões realizadas pelo modelo de mesoescala WRF e pela RNA pra previsões realizadas em até 24h, 48h ou em até 72h, para um dia de céu claro (14/02/2013) e dias de céu total ou parcialmente encoberto (07/02/2013) para o mês de fevereiro, quando comparados aos dados observados.



**Figura 10:** Gráficos comparativos entre previsões horárias (9h às 21h) de irradiância solar, nos dias 07 e 14 de fevereiro, produzidas pelos modelos WRF e RNA em até 24h, 48h e 72h e os dados observados na superfície na estação A551. É representado o comportamento das previsões em dia de céu claro (gráfico superior) e dias de céu parcial ou completamente encoberto (gráfico inferior).

Na **Figura 10**, é possível observar, para o dia de céu claro, que a previsão do modelo WRF é ligeiramente melhor para previsões de até 24h, quando comparadas às previsões de até 48h. No entanto, a sensibilidade de previsão do WRF começa a ter menos representatividade para as previsões de até 72h. O mesmo ocorre com os ajustes feitos pela RNA: os valores de irradiância solar fornecidos pela RNA com dados de previsão de até 72h são mais discrepantes dos dados observados na superfície, quando comparados à irradiância solar obtida com dados de previsão de até 24h e 48h. Observa-se que o comportamento das previsões do WRF e da RNA para o dia de céu parcialmente encoberto se mantém, ou seja, se aproximam mais dos dados de superfície quando as previsões são até 24h, tendendo a redução da correlação e aumento dos desvios conforme a previsão for realizada para horizonte maior de tempo. Para melhor visualização dos números apresentados na Figura 10, é possível observar na Tabela 10 os valores de irradiância solar observados na estação A551, bem como os valores previstos para rodadas iniciadas nos dias 14/02/2013 e 07/02/2013 pelo WRF e pela RNA, para os diferentes horários (24h, 48h e 72h).

Horário	WRF (W/m²)			RNA (W/m²)			A551
	24h	48h	72h	24h	48h	72h	
14/02/2013							
9h	4,51	18,05	6,25	24,45	22,53	28,47	1,40
10h	231,23	256,77	83,99	65,29	94,56	108,41	120,51
11h	535,92	517,29	247,85	265,46	409,85	347,65	392,46
12h	774,32	755,72	726,95	712,61	776,81	613,96	651,33
13h	960,32	947,30	938,42	940,09	997,64	649,74	870,07
14h	1081,55	1072,11	1051,66	1027,29	1084,17	933,92	1031,07
15h	1131,65	1124,84	1050,52	1111,12	1081,23	969,33	1097,90
16h	1100,13	1101,17	879,66	1082,04	1100,23	1073,92	1118,66
17h	999,57	1001,82	963,15	997,71	951,15	1005,78	1008,80
18h	824,56	833,53	763,56	860,99	894,12	796,61	911,31
19h	596,96	608,12	529,30	646,27	713,54	601,48	646,99
20h	333,04	306,56	308,18	323,03	371,22	339,91	414,11
21h	75,85	55,70	59,71	134,06	171,11	99,46	132,58
07/02/2013							
9h	11,38	26,28	12,94	23,53	25,85	70,40	2,12
10h	242,15	249,32	161,66	81,87	105,76	162,17	133,80
11h	544,51	517,59	497,93	379,82	305,83	326,00	359,69
12h	774,33	714,47	448,96	515,65	633,50	428,15	546,23
13h	880,59	942,69	645,59	521,93	790,20	616,24	641,25
14h	846,03	1068,17	1063,42	730,35	805,89	828,82	686,98
15h	1124,09	1120,8	1107,63	952,85	939,82	892,84	1045,30
16h	935,31	1096,69	775,43	988,64	802,93	834,06	952,52
17h	988,96	993,26	648,39	994,55	764,67	873,54	749,32
18h	817,29	533,38	560,14	838,14	769,12	711,44	785,96
19h	403,01	465,84	340,19	610,94	608,00	491,12	593,88
20h	329,84	295,47	250,41	243,72	239,15	250,78	276,38
21h	78,84	51,31	35,41	68,54	57,01	54,89	41,83

**Tabela 10:** Valores de irradiância solar (W/m<sup>2</sup>) incidente na superfície fornecidos pelo modelo WRF e pela RNA para os dias 07 e 14 de fevereiro para a estação A551, comparando as previsões de até 24h, 48h e 72h. A última coluna apresenta os valores observados na estação A551.

Na **Tabela 10**, observa-se que os dados de previsão de até 24h foram os que mais se aproximaram dos dados observados na estação A551, como dito anteriormente. Às 19h do dia 14, por exemplo, o valor observado de irradiância solar foi de 646,99 W/m<sup>2</sup>, enquanto a rede estimou 646,27 W/m<sup>2</sup>. Para o mesmo dia, às 14h, o valor medido de irradiância solar foi 1031,07 W/m<sup>2</sup>, enquanto o estimado foi 1027,29 W/m<sup>2</sup>. Às 21h, a RNA estimou 134,06 W/m<sup>2</sup>, enquanto o valor observado foi de 132,58 W/m<sup>2</sup>. Para o dia 7, de céu

parcial ou totalmente encoberto, os dados medidos e estimados são mais discrepantes, devido à dificuldade de simular os fenômenos não lineares associados à nebulosidade.

Para as previsões de até 48h e 72h, uma vez que foram estimados utilizando uma rede treinada com dados de previsões de até 24h, espera-se uma correlação menor entre os dados medidos e estimados. Mesmo assim, alguns valores estimados pela RNA também se aproximam bastante dos observados, como é o caso das 18h e 21h do dia 07, 15h e 16h do dia 14 para os dados de previsão de até 48h. Para 72h, em que há uma previsão ainda mais incerta, esperando-se uma correlação menor entre os dados medidos e estimados, algumas estimativas também se destacaram, como por exemplo os resultados de 10h e 17h do dia 14.

## 6. Conclusões

De acordo com os resultados expostos, pode-se afirmar que o objetivo proposto nesse trabalho foi alcançado, uma vez que foi obtido ganhos das previsões de irradiância solar com utilização das Redes Neurais Artificiais para o Sudeste Brasileiro, em comparação àquelas fornecidas diretamente pelo modelo de mesoescala WRF.

Fevereiro, junho e outubro são os meses com maiores incidências de radiação solar, porém, possuem características bastante distintas de acordo com cada estação do ano. Mesmo com tais diferenças, a RNA conseguiu prever de forma satisfatória para todos os meses e regiões homogêneas do Sudeste, reduzindo significativamente o RMSE e BIAS resultantes das previsões do WRF, ao passo que aumentou consideravelmente a correlação entre os dados observados e medidos.

Para todas as Regiões Homogêneas, os índices foram melhores no mês de junho, mostrando que a RNA é mais eficiente para o mês do ano em que a ocorrência de precipitação é menor. O modelo WRF claramente superestima a irradiação solar em todas as regiões homogêneas, embora se observe uma boa concordância entre os dados observados e previstos pela RNA. Observa-se ainda que os coeficientes de correlação se apresentam com bons níveis entre previsões e observações, sempre superiores à 87% em fevereiro, 94% em junho e 89% em outubro.

Devido aos excelentes resultados apresentados pela RNA para previsões de até 24h, optou-se por utilizar a mesma metodologia para previsões de diferentes horizontes de curto prazo, sendo eles 48h e 72h. Para todas as regiões homogêneas, em todos os meses, observou-se que quanto mais longo o horizonte, a correlação entre dados modelados e observados sofre uma redução, e maiores são os respectivos desvios, tanto para as previsões do WRF, quanto para as previsões da RNA.

No entanto, os índices estatísticos se mantiveram bons, sendo a média de correlação entre dados estimados pela RNA e observados, para o horizonte de 48h, de 80% em fevereiro, 85% em junho e 84% em outubro. Para o horizonte de 72h, as médias de correlação foram 78%, 82% e 81% para os referidos meses.

A metodologia proposta foi eficiente em todas as regiões homogêneas, na tarefa de redução do erro sistemático do WRF. Sendo assim, é possível a utilização do modelo WRF para previsão de irradiância solar incidente utilizando as redes neurais artificiais para o refinamento das saídas originais de irradiação solar do modelo WRF.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] GOLDENBERG, J.; VILLANUEVA, L. D. **Energia, meio Ambiente & desenvolvimento 2.** ed. São Paulo: Edusp—Editora da Universidade de São Paulo, 2003. 232p
- [2] Field, C.B., V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.). **Climate Change 2014: Impacts, Adaptation, and Vulnerability.** Part A and Part B. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1132 pp/688 pp.
- [3] WILD, M. **Global dimming and brightening: a review.** J. Geophys. Res., v. 114, D00D16, 2009. doi:10.1029/2008JD011470.
- [4] LIMA, F. J. L de. **Previsão de irradiação solar no Nordeste do Brasil empregando o modelo WRF ajustado por redes neurais artificiais (RNAs).** Tese de Doutorado – INPE, 2015. São José dos Campos, xxxiv + 216 p. CDU 551.521.31:004.032.
- [5] ANEEL -AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, MINISTÉRIO DE MINAS E ENERGIA. **Balanço Energético Nacional – BEN**, 2011: ano base 2010: resultados preliminares. Rio de Janeiro: Empresa de Pesquisa Energética, 2011.
- [6] PEREIRA, E. B.; MARTINS, F. R.; ABREU, S. L.; RUTHER, R. **Atlas brasileiro de energia solar.** São José dos Campos: INPE, 2006. 60p. ISBN 978-85-17-00030-0.
- [7] MARTINS, F. R., PEREIRA, E. B. **Estudo comparativo da confiabilidade de estimativas de irradiação solar para o sudeste brasileiras obtidas a partir de dados de satélite e por interpolação/extrapolação de dados de superfície.** Revista Brasileira de Geofísica. v. 29, n 2, p. 265-276, 2011.
- [8] MARTINS, F R.; PEREIRA, E. B.; SILVA S. DE A. B.; GUARNIERI, R.A. **Variabilidade e tendências regionais dos recursos de energia solar no Brasil.** In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 14, 2006, Florianópolis. Anais...Florianópolis: SBMET, 2006. CD-Rom.
- [9] LEAL S. S. E TIBA C. **Iluminância e irradiação solar global na região nordeste do Brasil.** In: VI Congresso Internacional sobre Geração Distribuída

e Energia no Meio Rural, 6, 2006, Campinas. Anais...Campinas: AGRENER, 2006. CD-Rom.

[10] MARTINS, F. R., PEREIRA, E. B., SILVA, S. A. B., ABREU, S. L., COLLE, S. **Solar energy scenarios in Brasil, Parto one: Resource assessment.** Energy Policy. v. 36, p. 2843-2854, 2008.

[11] CEBALLOS, J. C.; BOTTINO, M. J. **Modelo de estimativa de radiação solar por satélite no CPTEC: Versão GL 1.2.** In: XII Congresso Brasileiro de Meteorologia, 12, 2002, Foz do Iguaçu. Anais...Foz do Iguaçu: SBMET, 2002, CD-Rom.

[12] CEBALLOS, J. C.; BOTTINO, M. J. **Estimativa de radiação solar por satélite: Desempenho do modelo operacional GL1.2.** In: XIII Congresso Brasileiro de Meteorologia, 13, 2004, Fortaleza. Anais...Fortaleza: SBMET, 2004, CD-Rom.

[13] GUARNIERI, R. A. **Emprego de redes neurais artificiais e regresso linear múltipla no refinamento das previsões de radiação solar do modelo ETA.** 2006. 171 p. (INPE-14172-TDI/1089). Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

[14] PEREIRA, E. B.; ABREU, S. L.; STUHLMANN, R.; RIELAND, M.; COLLE, S. **Survey of the incident solar radiation in Brazil by the use of the METEOSAT satellite data.** Solar Energy, v. 57, n. 2, p. 125-132, 1996.

[15] MARTINS, F.R. **Influência do processo de determinação da cobertura de nuvens e dos aerossóis de queimada no modelo físico de radiação BRASIL-SR.** 2001. Tese de Doutorado -INPE, São José dos Campos.

[16] BASSEUR, G. E SOLOMON, S., **Aeronomy of the middle atmosphere.** D. Reidel Publishing, Dordrecht, Netherlands, 1986.

[17] KONDRATYEV, K. YA., **Radiation in the atmosphere.** New York: Academic Press, 912p, 1969.

[18] LIOU, K. N., **An introduction to atmospheric radiation.** New York: Academic Press Inc., 392p, 1980.

[19] KIDDER, S. Q.; VONDER HAAR, T. H., **Satellite meteorology: an introduction.** San Diego: Academic Press, p. 466,1995.

[20] PLANA-FATTORI, A.; CEBALLOS, J. C., **Glossário de termos técnicos em radiação atmosférica - versão 2.0.** IAG/USP – CPTEC/INPE, São Paulo,



2005. Disponível em: <<http://pyata.cptec.inpe.br/radiacao/glossar/glossar.htm>>. Acessado em: 23 de julho, 2015.

[21] ROBINSON, N. (ed.), **Solar radiation**. Amsterdam: Elsevier Publishing Company, p. 347, 1966.

[22] ALVES, A. R. **Irradiância solar global em superfície de diferentes inclinações e azimutes para Viçosa, MG**. 1981. 92 p. Dissertação ( Mestrado em Engenharia Agrícola) –Universidade Federal de Viçosa: Viçosa, 1981.

[23] LESTRADE, J. P. **The effect of cloud layer plane albedo on global and diffuse isolation**. Solar Energy. Elmsford, New York, v.44, n.22, p.115-121, 1990.

[24] ECHER, E.; SOUSA M. P.; SCHUCH, N. J. **Alei de Beer aplicada na atmosfera terrestre**. Revista Brasileira de Física, São Paulo, v.23, n.3, p.276-283, 2001.

[25] LIOU, K. N. **On the Absorption, Reflection and Transmission of Solar Radiation in Cloudy Atmospheres**. J. Atmosphere Sciences, v. 33, n.1, p.798-804, 1976.

[26] SOUZA, J.L. **Irradiância solar no litoral do Nordeste: Avaliação Preliminar**. In: X Congresso Brasileiro de Agrometeorologia, 1997, Piracicaba. Anais...Piracicaba: Sociedade Brasileira de Agrometeorologia, 1997.p.457-459.

[27] AGUIAR, R. **Climatic synthetic series for the Mediterrabean belt**. The European Commission, on Nuclear Energy Programme Joule III, Contract JOR3-CT96-0042.Lisboa, Portugal: Instituto Nacional de Engenharia e Tecnologia Industrial, 1997.Final Report.

[28] SEGAL, M. & DAVIS, J. **The impact of deep cumulus reflection on the ground-level global irradiance**. Journal Applied Meteorology, v. 31, p.217-222, 1992.

[29] PALIATSOS, A.G., KAMBEZIDIS, H.D., ANTONIOU, A. **Diffuse solar irradiation at a location in the Balkan Península**. Renewable Energy. v. 28, p. 2147-2156, 2003.

[30] SOUZA, J.L., NICÁCIO, R.M., LIMA MOURA, M.A. **Global solar radiation measurements in Maceió, Brazil**. Renewable Energy, v. 30, p. 1203-1220, 2005.

[31] SILVA, V. P. R.; CAVALCANTI, E. P.; BRAGA, C. C.; VIEIRA, P.V. **Evaluating trends in solar radiation based on data fields from the**

**NCEP/NACR reanalysis and measurements, 7th EMS Annual Meeting / 8th ECAM.** El Escorial (Madrid, Spain), October 2007.

[32] ARTAXO, P; OLIVEIRA, P. H; LARA L. L; PAULIQUEVIS, T. M; RIZZO, L. V; PIRES JUNIOR, C; PAIXÃO, M. A; LONGO, K. M; FREITAS, S; CORREIA, A. L. **Efeitos climáticos de partículas de aerossóis biogênicos e emitidos em queimadas na Amazônia.** Revista Brasileira de Meteorologia, v.21, n.3, p.168- 22, 2006.

[33] LIEPERT B. G.; KUKLA, G. J. **Decline in solar radiation with increased horizontal variability in Germany between 1964–1990.** J. Climate, v.10, n.1, p.2391-2401, 1997.

[34] KAUFMAN, Y. J.; NAKAJIMA, T. **Effect of Amazon smoke on cloud microphysics and albedo - Analysis from satellite imagery.** J. Applied Meteor., v.32, n.4, p.729-744, 1993.

[35] TWOMEY, S. **The influence of pollution on the shortwave albedo of clouds.** Journal of the Atmospheric Sciences, v.34, p.1149-1152, 1977.

[36] KAUFMAN, Y. J.; FRASER, R. S. **Confirmation of smoke particles effect on clouds and climate forcing.** Science, v.277, p.1636-1639, 1997.

[37] VOYANT, C.; NOTTON, G.; KALOGIROU, S.; NIVET, M.L.; PAOLI, C.; MOTTE, F.; FOUILLOY, A. **Machine learning methods for solar radiation forecasting: A review.** Renewable Energy, v.105, p.569-582, 2017.

[38] DIAGNE, M; DAVID, M.; LAURET, P.; BOLAND, J.; SCHMUTZ, N. **Review of solar irradiance forecasting methods and a proposition for small-scale insular grids.** Renewable and Sustainable Energy Reviews v.27, p. 65–76, 2013. EPE. **Análise da Inserção da Geração Solar na Matriz Elétrica Brasileira.** Rio de Janeiro, 2012.

[39] SKAMAROCK, W. C.; KLEMP, J. B.; DUDHIA, J.; GILL, D. O.; BARKER, D. M.; WANG, W.; POWERS, J. G. **A Description of the Advanced Research WRF Version 2.** Boulder: National Center for Atmospheric Research, 2005.

[40] SKAMAROCK, W. C.; KLEMP, J. B.; DUDHIA, J. et al. **Description of the Advanced Research WRF Version 3.** Boulder: National Center for Atmospheric Research, 2008.

[41] Chou, M.-D., R. S. Lindzen, and A. Y. Hou, 2002: **Comments on “The iris hypothesis: A negative or positive cloud feedback?”** J. Climate, 15, 2713–2715.

- [42] Hinkelman, L. M., Ackerman, T. P., Marchand, R. T., 1999. **An evaluation of NCEP Eta model predictions of surface energy budget and cloud properties by comparison with measured ARM data.** Journal of Geophysical Research, vol.104, n. D16, pp. 19535-19549.
- [43] BRAGA A.P., CARVALHO A.C.P.F. E LUDERMIR T.B. **Fundamentos de Redes Neurais Artificiais.** 11a Escola de Computação. Universidade Federal do Rio de Janeiro, p. 246, Rio de Janeiro, 1998.
- [44] FIORIN, DANIEL V.; MARTINS, FERNANDO R.; SCHUCH, NELSON J.; PEREIRA, ENIO B., **Aplicações de Redes neurais e previsões de disponibilidade de recursos energéticos solares.** Revista Brasileira de Ensino de Física, v.33, n.1, p. 1309, 2011.
- [45] HEBB D.O., **The Organization of Behavior.** Willey, New York, 1949.
- [46] ROSENBLATT, F., The perceptron: **A probabilistic model for information storage and organization.** Psychological Review. v. 65, p. 386, 1958.
- [47] WIDROW B. E M.E. HO®, **Proceedings of IREWESCON Convention Record.** Institute of Radio Engineers, Los Angeles, v. 4, p. 96-104, 1960.
- [48] MINSKY M. E PAPERT S., **Artificial Intelligence Progress Report.: Technical Report.** UMI Order Number: AIM-252, Massachusetts Institute of Technology Press, Massachusetts, 1972.
- [49] RUMELHART D.E.; G.E. HINTON; R.J. WILLIAMS, **Learning representations by back-propagating errors.** Nature, vol. 323, p. 533, doi:10.1038/323533a0, 1986.
- [50] HAYKIN, S., **Neural networks: a comprehensive foundation.** New York: Macmillan College Publishing Company, 1994.
- [51] HORNIK, K.; STINCHCOMBE, M.; WHITE, H., **Multilayer feed forward network are universal approximators.** Neural Networks, v. 2, n. 5, p. 359-366, 1989.
- [52] AL-ALAWI S.M. E AL-HINAI H.A., **An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation.** Renewable Energy, v. 14, p. 199, 1998.

- [53] MOHANDES M., REHMAN S. E HALAWANI T.O., **Estimation of global solar radiation using artificial neural networks**. Renewable Energy v. 14, p. 179, 1998.
- [54] KALOGIROU, S.; MICHAELIDES, S.; TYMBIOS, F.; **Prediction of maximum solar radiation using artificial neural networks**. Proceedings of WREC VII, Germany, 2002.
- [55] CAVALCANTI, I. F. A.; FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS, M. A.. **Tempo e clima no Brasil**. São Paulo: Oficina de Textos, 2009, cap. 13, p. 197-212.
- [56] MOTA, M.A.S.; NOBRE, C.A. **Relação da variabilidade da energia potencial convectiva disponível (CAPE) com a precipitação e a alta da Bolívia durante a campanha Wet-AMC/LBA**. Revista Brasileira de Meteorologia, Brasil, v. 21, n. 3b, p. 344-355. 2006.
- [57] LOPES, A. F. de M., **Avaliação da Chuva em Episódios de ZCAS na Região Sudeste do Brasil - Estudo de Caso: Bacia do Rio Grande** Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Civil – Rio de Janeiro, 2016.
- [58] REBOITA M.S., GAN M. A., DA ROCHA R. P., AMBRIZZI T. **Regimes de precipitação na América do Sul: Uma Revisão Bibliográfica**. Revista Brasileira de Meteorologia, 25(2):185-204, 2010.
- [59] ROESCH, A.; WILD, M.; OHMURA, A.; DUTTON, E. G.; LONG, C. N.; ZHANG, T. **Assessmente of BSRN radiation records for the computation of monthly means**. Atmos. Meas. Tech., v. 4, p. 339-354,2011.
- [60] LIMA, F. J. L de. Trabalho de pós doutorado em desenvolvimento.
- [61] WARD, J. H. **Hierarchical grouping of optimize na objective function**. Journal of American Statistical Association,v. 58, p. 236-244, 1963.
- [62] LECKNER, B. **The spectral distribution of solar radiation at the Earth's surface – elements of a model**. Solar Energy, 20, 2, 143-150, 1978.
- [63] GAMBI, W. **Avaliação de um modelo físico estimador de irradiância solar baseado em satélites geoestacionários**. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal de Santa Catarina. Florianópolis,1998.
- [64] DIEKMANN, F. J.; RASCHKE, E.; WOICK H. **Operational mapping of global radiation over Central Europe**. Meteorol. Rdsch., 39, 59-63, 1986.

- [65] IQBAL, M. An introduction to solar radiation. New York: Academic press, 1983.
- [66] HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman Companhia Editora, 2001. 900p.
- [67] REED, R. **Pruning algorithms – a survey**. IEEE Transactions on Neural Networks, v.4, n.5, p. 740-746, 1993.
- [68] DAVIES, J.A.; McKAY, D.C.; LUCIANI, G.; ABDEL-WAHAB, M. **Validation of models estimating solar radiation on horizontal surfaces**. Task IX Final Report to the Solar Heating and Cooling Programme of the International Energy Agency, 1988.
- [69] DJEMAA, B.; DELORME, C. **A comparison between one year of daily global irradiation from a ground-based measurements versus Meteosat images from seven locations in Tunisia**. Solar Energy 48, 325–333, 1992.
- [70] PEREZ, R.; SEALS, R.; ZELENKA, A. **Comparing satellite remote sensing and ground network measurements for the production of site/time specific irradiance data**. Solar Energy, v. 60, n. 2, p. 89-96, 1997.
- [71] ARGIRIOU, A.; LYKOUDIS, S.; KONTOYIANNIDIS, S.; BALARAS, C.A.; ASIMAKO-POULOS, D.; PETRADIS, M.; KASSOMENOS, P. **Comparison of methodologies for TMY generation using 20 years data for Athens, Greece**. Solar Energy 66, 33–45, 1999.
- [72] SCHILLINGS, C.; MEYER, R.; MANNSTEIN, H. **Validation of a method for deriving high resolution direct normal irradiance from satellite data and application for the Arabian Peninsula**. Solar Energy, v. 76, p. 485–497, 2003.
- [73] LEFÈVRE, M.; WALD, L.; DIABATE', L. **Using reduced data sets ISCCP-B2 from the Meteosat satellites to assess surface solar irradiance**. Solar Energy 81, 240–253, 2007.